



**TUGAS AKHIR – SS141501**

**PENERAPAN MODEL *HYBRID ARIMAX-QUANTILE REGRESSION* UNTUK PERAMALAN *INFLOW* DAN *OUTFLOW* PECAHAN UANG KARTAL DI JAWA TIMUR**

**NOVI AJENG SALEHAH  
NRP. 1313 100 051**

**Dosen Pembimbing  
Dr. Suhartono  
Dr. rer. pol. Dedy Dwi Prastyo, M.Si**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2017**





**TUGAS AKHIR – SS141501**

**PENERAPAN MODEL *HYBRID ARIMAX-QUANTILE REGRESSION* UNTUK PERAMALAN *INFLOW* DAN *OUTFLOW* PECAHAN UANG KARTAL DI JAWA TIMUR**

**NOVI AJENG SALEHAH  
NRP. 1313 100 051**

**Dosen Pembimbing  
Dr. Suhartono  
Dr. rer. pol. Dedy Dwi Prastyo, M.Si.**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2017**





**FINAL PROJECT – SS 141501**

***HYBRID ARIMAX-QUANTILE REGRESSION MODEL FOR  
FORECASTING INFLOW AND OUTFLOW  
DENOMINATION OF CURRENCY  
IN EAST JAVA***

**NOVI AJENG SALEHAH  
NRP. 1313 100 051**

**Supervisor  
Dr. Suhartono  
Dr. rer. pol. Dedy Dwi Prastyo, M.Si.**

**UNDERGRADUATE PROGRAMME  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS AND NATURAL SCIENCES  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2017**



## LEMBAR PENGESAHAN

### **PENERAPAN MODEL *HYBRID* ARIMAX-QUANTILE REGRESSION UNTUK PERAMALAN *INFLOW* DAN *OUTFLOW* PECAHAN UANG KARTAL DI JAWA TIMUR**

#### **TUGAS AKHIR**

Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Sains  
pada  
Program Studi Sarjana Departemen Statistika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember

Oleh :

**Novi Ajeng Salehah**  
NRP. 1313 100 051

Disetujui oleh Pembimbing Tugas Akhir :

Dr. Suhartono  
NIP. 19710929 199512 1 001

Dr. rer. pol. Dedy Dwi P., M.Si  
NIP. 19831204 200812 1 002

Mengetahui,  
Kepala Departemen



Dr. Suhartono

NIP. 19710929 199512 1 001

SURABAYA, JULI 2017





# **PENERAPAN MODEL *HYBRID* ARIMAX-QUANTILE REGRESSION UNTUK PERAMALAN INFLOW DAN OUTFLOW PECAHAN UANG KARTAL DI JAWA TIMUR**

**Nama** : Novi Ajeng Salehah  
**NRP** : 1313100051  
**Departemen** : Statistika  
**Dosen Pembimbing 1** : Dr. Suhartono  
**Dosen Pembimbing 2** : Dr. rer. pol. Dedy Dwi Prastyo, M.Si.

## **Abstrak**

*Bank Indonesia memiliki tujuan untuk memenuhi kebutuhan uang di masyarakat dan salah satu faktor yang menjadi pertimbangan dalam penyusunan Rencana Kebutuhan Uang oleh Bank Indonesia adalah nilai inflow dan outflow. Berdasarkan hal tersebut, peramalan inflow dan outflow menjadi hal penting demi mendukung tujuan Bank Indonesia dimana diperlukan suatu model peramalan yang mampu merekonstruksi pola tren, musiman dan variasi kalender serta heteroskedastisitas pada data inflow dan outflow. Penelitian ini menerapkan model hybrid ARIMAX-Quantile Regression serta beberapa model individu lainnya dengan menggunakan dummy efek variasi kalender Hari Raya Idul Fitri untuk meramalkan inflow dan outflow pecahan uang kartal di Jawa Timur. Data yang digunakan adalah data sekunder dari Bank Indonesia mengenai inflow dan outflow per pecahan pada periode Januari 2003 hingga Desember 2016. Terdapat empat model ARIMAX-Quantile Regression yang diterapkan pada penelitian ini. Hasil studi simulasi dan analisis pada data real menunjukkan bahwa model ARIMAX-Quantile Regression mampu menangkap pola variasi kalender pada data. Model ARIMAX-Quantile Regression baik digunakan untuk meramalkan outflow pecahan Rp50.000,00 dan Rp2.000,00 serta inflow pecahan Rp50.000,00 hingga Rp1.000,00 sedangkan pecahan lain baik diramalkan menggunakan model individu lain.*

*Berdasarkan hasil perbandingan kriteria kebaikan model menggunakan RMSE, MAE dan MdAE ditunjukkan bahwa model hybrid ARIMAX-Quantile Regression menghasilkan ramalan titik yang baik dibanding metode individu yang lain.*

***Kata Kunci : ARIMAX, Hybrid, Inflow, Outflow, Quantile Regression.***

# **HYBRID ARIMAX-QUANTILE REGRESSION MODEL FOR FORECASTING INFLOW AND OUTFLOW DENOMINATION OF CURRENCY IN EAST JAVA**

**Name** : Novi Ajeng Salehah  
**NRP** : 1313100051  
**Department** : Statistics  
**Supervisor 1** : Dr. Suhartono  
**Supervisor 2** : Dr. rer. pol. Dedy Dwi Prastyo,  
M.Si

## **Abstract**

*One of the purposes of Bank Indonesia is to fulfill the needs of money in the community and some factors which considered to this situation are the value of inflow and outflow. Based on this condition, inflow and outflow forecasting become necessary to arrange the plan that will help Bank Indonesia to reach its purpose. A forecasting model is necessary to reconstruct trend, seasonal, and calendar variation patterns and also heteroscedasticity of inflow and outflow data. This study applies hybrid ARIMAX-Quantile Regression and other individual methods using dummy variable of Eid Mubarak calendar variation to predict amount of inflow and outflow. In this study, there are two main topics will be discussed, simulation study and case study in real data. There are four types of ARIMAX-Quantile Regression models that used. The results of this study show that ARIMAX-Quantile Regression model is able to capture the pattern of calendar variation in the data. The outflow data of Rp50.000,00 and Rp2.000,00 and the inflow of Rp50.000,00; Rp20.000,00; Rp10.000,00; Rp5.000,00; Rp2.000,00; and Rp1.000,00 are better forecasted using ARIMAX-Quantile Regression model than using time series regression or ARIMAX. In general, based on model fitting criteria comparison using RMSE, MAE and MdAE,*

*ARIMAX-Quantile Regression method performs better forecast compared to other individual methods.*

***Keywords : ARIMAX, Hybrid, Inflow, Outflow, Quantile Regression.***

## KATA PENGANTAR

Puji syukur yang kehadirat Allah SWT, Tuhan Yang Maha Esa. Berkat rahmat dan ridho-Nya penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul **“Penerapan Model Hybrid ARIMAX-Quantile Regression untuk Peramalan Inflow dan Outflow Pecahan Uang Kartal di Jawa Timur”** dengan lancar.

Keberhasilan penyusunan Tugas Akhir ini tidak lepas dari banyaknya bantuan dan dukungan yang diberikan dari berbagai pihak. Penulis mengucapkan terima kasih kepada:

1. Bapak Dr. Suhartono selaku Kepala Departemen Statistika dan Bapak Dr. Sutikno, M.Si selaku Koordinator Program Studi Sarjana yang telah memberikan fasilitas untuk kelancaran penyelesaian Tugas Akhir.
2. Bapak Dr. Suhartono dan Bapak Dr. rer. pol. Dedy Dwi Prastyo, M.Si selaku dosen pembimbing yang dengan sabar telah memberikan bimbingan, ilmu, saran, dan dukungan selama penyusunan Tugas Akhir.
3. Ibu Dr. Kartika Fithriasari, M.Si dan Bapak Dr.rer.pol Heri Kuswanto, M.Si selaku dosen penguji yang telah memberikan banyak bantuan dan saran untuk Tugas Akhir ini.
4. Bapak Dra. Kartika Fithriasari, M.Si dan Dra. Sri Mumpuni Retnaningsih, M.T. selaku dosen wali yang telah memberikan nasehat dan semangat selama masa perkuliahan.
5. Ibu dan Bapak tercinta, kakak tersayang serta keluarga yang selalu memberikan dukungan, kasih sayang, semangat, dan doa yang tidak pernah putus kepada penulis.

Penulis berharap hasil Tugas Akhir ini dapat bermanfaat bagi kita semua. Semoga kebaikan dan bantuan yang telah diberikan kepada penulis dibalas dengan kebaikan yang lebih besar lagi oleh Tuhan Yang Maha Esa. Aamiin.

Surabaya, Juli 2017

Penulis

*(halaman ini sengaja dikosongkan)*

## DAFTAR ISI

<b>HALAMAN JUDUL.....</b>	<b>i</b>
<b>LEMBAR PENGESAHAN.....</b>	<b>v</b>
<b>ABSTRAK.....</b>	<b>vii</b>
<b>ABSTRACT .....</b>	<b>ix</b>
<b>KATA PENGANTAR .....</b>	<b>xi</b>
<b>DAFTAR ISI.....</b>	<b>xiii</b>
<b>DAFTAR GAMBAR .....</b>	<b>xv</b>
<b>DAFTAR TABEL.....</b>	<b>xxi</b>
<b>DAFTAR LAMPIRAN .....</b>	<b>xxv</b>
<b>BAB I PENDAHULUAN</b>	
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian .....	5
1.4 Manfaat Penelitian .....	5
1.5 Batasan Masalah .....	6
<b>BAB II TINJAUAN PUSTAKA</b>	
2.1 Uang Kartal.....	7
2.2 ACF dan PACF .....	9
2.3 Model <i>Autoregressive Integrated Moving Average</i> (ARIMA) .....	9
2.3.1 Identifikasi Model.....	11
2.3.2 Estimasi dan Pengujian Parameter.....	14
2.3.3 Cek Diagnosa.....	16
2.3.4 Pemilihan Model Terbaik .....	18
2.4 <i>Time Series Regression</i> .....	19
2.5 Model <i>Autoregressive Integrated Moving Average</i> <i>with Exogeneous Variable</i> (ARIMAX).....	21
2.6 <i>Quantile Regression</i> .....	22
2.7 <i>ARIMAX-Quantile Regression</i> (ARIMAX-QR).....	28
2.8 Evaluasi Model .....	30
<b>BAB III METODOLOGI PENELITIAN</b>	
3.1 Sumber Data .....	33
3.2 Variabel Penelitian.....	33

3.3	Langkah Penelitian.....	36
3.3.1	Studi Simulasi.....	36
3.3.2	Peramalan <i>Inflow</i> dan <i>Outflow</i> Jawa Timur .....	38
3.3.3	Diagram Alir.....	43
<b>BAB IV ANALISIS DAN PEMBAHASAN</b>		
4.1	Studi Simulasi .....	49
4.1.1	Studi Simulasi Skenario 1 (Varians Musiman Homogen) .....	51
4.1.2	Studi Simulasi Skenario 2 (Varians Musiman Heterogen) .....	68
4.2	Karakteristik Data <i>Inflow</i> dan <i>Outflow</i> Uang Kartal di Jawa Timur.....	85
4.3	Pemodelan <i>Inflow</i> dan <i>Outflow</i> Uang Kartal di Jawa Timur Menggunakan <i>Time Series Regression</i> .....	99
4.4	Pemodelan <i>Inflow</i> dan <i>Outflow</i> Uang Kartal di Jawa Timur Menggunakan ARIMAX (ARIMA dengan Variasi Kalender) .....	115
4.5	Pemodelan <i>Inflow</i> dan <i>Outflow</i> Uang Kartal di Jawa Timur Menggunakan ARIMAX- <i>Quantile Regression</i> (ARIMAX-QR).....	124
4.5.1	ARIMAX- <i>Quantile Regression</i> Model 1 .....	125
4.5.2	ARIMAX- <i>Quantile Regression</i> Model 2 .....	133
4.5.3	ARIMAX- <i>Quantile Regression</i> Model 3.....	136
4.5.4	ARIMAX- <i>Quantile Regression</i> Model 4 .....	141
4.6	Perbandingan Kebaikan Hasil Ramalan Data <i>Inflow</i> dan <i>Outflow</i> per Pecahan Menggunakan Metode <i>Time Series Regression</i> , ARIMAX dan ARIMAX-QR .....	144
<b>BAB V KESIMPULAN DAN SARAN</b>		
5.1	Kesimpulan .....	165
5.2	Saran .....	166
<b>DAFTAR PUSTAKA .....</b>		167
<b>LAMPIRAN .....</b>		171



## DAFTAR GAMBAR

Gambar 2.1	Ilustrasi Menghitung Nilai Kuantil dari Distribusi Normal Standar .....	24
Gambar 2.2	Ilustrasi Estimasi Parameter Regresi Klasik OLS dan Regresi Kuantil .....	27
Gambar 3.1	Diagram Alir Penelitian .....	43
Gambar 3.2	Diagram Alir Penelitian ARIMAX-QR Model 1 (Arunraj & Ahrens, 2015) .....	44
Gambar 3.3	Diagram Alir Penelitian ARIMAX-QR Model 2 ..	45
Gambar 3.4	Diagram Alir Penelitian ARIMAX-QR Model 3 ..	46
Gambar 3.5	Diagram Alir Penelitian ARIMAX-QR Model 4 ..	47
Gambar 4.1	Jangkauan data Simulasi untuk pola Tetap .....	50
Gambar 4.2	Plot Jangkauan Pola Musiman Data Simulasi Skenario 1 .....	51
Gambar 4.3	Plot <i>Time Series</i> Data (a), dan <i>Boxplot</i> dari Data yaitu yang dikategorikan Tiap Bulan (b) serta Setelah Dihilangkan Pola Tren dan Variasi Kalender (c), dari Data Simulasi Skenario 1 .....	52
Gambar 4.4	Plot ACF dan PACF Residual Model TSR Skenario 1 Replikasi 1 .....	53
Gambar 4.5	Plot ACF Data Simulasi Skenario 1 Replikasi 1 ...	57
Gambar 4.6	Plot ACF dan PACF Data Simulasi Skenario 1 Replikasi 1 Setelah <i>Differencing</i> .....	57
Gambar 4.7	Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 1 .....	60
Gambar 4.8	Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 2 .....	61
Gambar 4.9	Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 3 .....	63
Gambar 4.10	Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 4 .....	64

Gambar 4.11	Rasio Kesalahan Ramalan Metode ARIMAX-QR terhadap metode ARIMAX pada Skenario 1.....	68
Gambar 4.12	Plot Jangkauan Pola Musiman Non-homogen Data Simulasi Skenario 2 .....	69
Gambar 4. 13	Plot <i>Time Series</i> Data (a), dan <i>Boxplot</i> dari Data yaitu yang Dikategorikan Tiap Bulan (b) serta Setelah Dihilangkan Pola Tren dan Variasi Kalender (c), dari Data Simulasi Skenario 2 .....	70
Gambar 4. 14	Plot ACF dan PACF Residual Model TSR Skenario 2 Replikasi 1 .....	71
Gambar 4.15	Plot ACF Data Simulasi Skenario 2 Replikasi 1 ...	73
Gambar 4.16	Plot ACF Dan PACF Data Simulasi Skenario 2 Replikasi 1 Setelah <i>Differencing</i> .....	73
Gambar 4.17	Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 2 menggunakan ARIMAX-QR Model 1 .....	76
Gambar 4. 18	Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 2 menggunakan ARIMAX-QR Model 2 .....	77
Gambar 4.19	Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 3 .....	78
Gambar 4.20	Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 4 .....	80
Gambar 4.21	Rasio Kesalahan Ramalan Metode ARIMAX-QR terhadap metode ARIMAX pada Skenario 2 .....	84
Gambar 4.22	Pola Kenaikan <i>Inflow</i> dan <i>Outflow</i> di Jawa Timur .....	85
Gambar 4.23	<i>Boxplot Inflow</i> di Jawa Timur .....	87
Gambar 4.24	<i>Time Series Plot Inflow</i> di Jawa Timur .....	87
Gambar 4.25	Rata-rata <i>Inflow</i> pada Saat dan Setelah Hari Raya Idul Fitri .....	88
Gambar 4.26	<i>Time Series Plot Outflow</i> di Jawa Timur .....	90

Gambar 4.27	Rata-rata <i>Outflow</i> pada Saat dan Sebelum Hari Raya Idul Fitri .....	91
Gambar 4.28	Pola Kenaikan <i>Inflow</i> dan <i>Outflow</i> di Jawa Timur Per Pecahan .....	93
Gambar 4.29	<i>Time Series Plot</i> Data <i>Inflow</i> di Jawa Timur Per Pecahan .....	93
Gambar 4.30	<i>Boxplot</i> Bulanan Data <i>Inflow</i> di Jawa Timur Per Pecahan .....	95
Gambar 4.31	<i>Time Series Plot</i> Data <i>Outflow</i> per Pecahan .....	96
Gambar 4.32	<i>Boxplot</i> Bulanan Data <i>Outflow</i> di Jawa Timur Per Pecahan .....	97
Gambar 4.33	Plot Data Aktual dan Ramalan <i>Outflow</i> Pecahan Rp100.000,00 pada Data <i>Out-sample</i> Menggunakan Model TSR .....	105
Gambar 4.34	Box-Cox Data <i>Outflow</i> pecahan Rp100.000,00 .	106
Gambar 4. 35	Plot Data Aktual dan Ramalan <i>Outflow</i> Pecahan Rp100.000,00 pada data <i>Out-sample</i> menggunakan Model TSR dengan Transformasi .....	108
Gambar 4.36	Perbandingan Model TSR Data Aktual dengan nilai Ramalan <i>Out-sample</i> Data <i>Outflow</i> Per Pecahan .....	112
Gambar 4.37	Perbandingan Model TSR Data Aktual dengan nilai Ramalan <i>Out-sample</i> Data <i>Inflow</i> Per Pecahan .....	113
Gambar 4.38	Plot ACF dan PACF Residual Model TSR <i>Outflow</i> pecahan Rp100.000,00 .....	115
Gambar 4.39	Plot Data Aktual dan Ramalan <i>Outflow</i> Pecahan Rp100.000,00 pada data <i>Out-sample</i> menggunakan Model ARIMAX .....	118
Gambar 4.40	Plot Data Aktual dan Ramalan <i>Outflow</i> Pecahan Rp100.000,00 pada data <i>Out-sample</i> menggunakan Model ARIMAX dengan Transformasi.....	121
Gambar 4.41	Perbandingan Model ARIMAX Data Aktual dengan nilai Ramalan <i>Out-sample</i> Data <i>Outflow</i> Per Pecahan .....	122

Gambar 4.42	Perbandingan Model ARIMAX Data Aktual dengan nilai Ramalan <i>Out-sample</i> Data <i>Inflow</i> Per Pecahan .....	123
Gambar 4.43	Plot ACF Dan PACF Data <i>Outflow</i> Pecahan Rp100.000,00 Setelah Transformasi .....	125
Gambar 4.44	Plot ACF dan PACF Data <i>Outflow</i> Pecahan Rp100.000,00 Setelah Transformasi dan <i>Differencing</i> .....	126
Gambar 4.45	Perbandingan Model ARIMAX-QR Model 1 Data Aktual dengan nilai Ramalan <i>out-sample</i> Data <i>Outflow</i> Per Pecahan.....	130
Gambar 4. 46	Perbandingan Model ARIMAX-QR Model 1 Data Aktual dengan nilai Ramalan <i>out-sample</i> Data <i>Inflow</i> Per Pecahan.....	131
Gambar 4.47	Perbandingan Model 2 ARIMAX-QR Data Aktual dengan Nilai Ramalan <i>out-sample</i> Data <i>Outflow</i> Per Pecahan .....	134
Gambar 4.48	Perbandingan Model 2 ARIMAX-QR Data Aktual dengan Nilai Ramalan <i>out-sample</i> Data <i>Inflow</i> Per Pecahan .....	135
Gambar 4.49	Perbandingan Model ARIMAX-QR Model 3 Data Aktual dengan nilai Ramalan <i>out-sample</i> Data <i>Outflow</i> Per Pecahan.....	138
Gambar 4.50	Perbandingan Model ARIMAX-QR Model 3 Data Aktual dengan nilai Ramalan <i>out-sample</i> Data <i>Inflow</i> Per Pecahan.....	139
Gambar 4.51	Perbandingan Model 4 ARIMAX-QR Data Aktual dengan Nilai Ramalan <i>out-sample</i> Data <i>Outflow</i> Per Pecahan .....	142
Gambar 4.52	Perbandingan Model 4 ARIMAX-QR Data Aktual dengan Nilai Ramalan <i>out-sample</i> Data <i>Inflow</i> Per Pecahan .....	143
Gambar 4.53	Perbandingan Hasil Ramalan <i>Out-sample</i> Tiap Metode pada Data <i>Outflow</i> .....	145

Gambar 4.54	Perbandingan Hasil Ramalan <i>Out-sample</i> Tiap Metode pada Data <i>Inflow</i> .....	146
Gambar 4.55	Rasio RMSE (a) dan MdAE (b) antar metode pada ramalan <i>out-sample</i> data <i>Outflow</i> .....	149
Gambar 4.56	Rasio RMSE (a) dan MdAE (b) antar metode pada ramalan <i>out-sample</i> data <i>Inflow</i> .....	150
Gambar 4.57	Perbandingan RMSE <i>Adaptive</i> Ramalan <i>Out-sample</i> Data <i>Outflow</i> Per Pecahan Tiap Metode	151
Gambar 4.58	Perbandingan RMSE <i>Adaptive</i> Ramalan <i>Out-sample</i> Data <i>Inflow</i> Per Pecahan Tiap Metode...	152

*(halaman ini sengaja dikosongkan)*

## DAFTAR TABEL

Tabel 2.1	Transformasi Box-Cox.....	12
Tabel 2.2	Karakteristik ACF dan PACF untuk model ARIMA Non-Musiman .....	12
Tabel 2.3	Karakteristik ACF dan PACF untuk model ARIMA Musiman .....	13
Tabel 3.1	Variabel Penelitian.....	33
Tabel 3.2	Daftar Hari Raya Idul Fitri tahun 2001-2016.....	35
Tabel 4.1	Uji Ljung-Box Residual Model TSR Skenario 1 Replikasi 1.....	54
Tabel 4.2	Uji Asumsi Distribusi Normal Residual Model TSR Data .....	54
Tabel 4.3	Estimasi dan Signifikansi Parameter Model ARIMA Residual TSR Simulasi Skenario 1 .....	55
Tabel 4.4	Pemenuhan Asumsi Model ARIMA Residual TSR Simulasi Skenario 1.....	56
Tabel 4.5	Model ARIMA dan Pengujian Asumsi Data tiap Replikasi Skenario 1.....	58
Tabel 4.6	Estimasi Koefisien ARIMAX-QR Model 1 Data Skenario 1 Replikasi 1.....	59
Tabel 4.7	Estimasi Parameter ARIMAX-QR Model 2 Residual Data Replikasi 1 Skenario 1 .....	61
Tabel 4.8	Estimasi Parameter ARIMAX-QR Model 3 Residual Data Replikasi 1 Skenario 1 .....	62
Tabel 4.9	Estimasi Parameter ARIMAX-QR Model 4 Residual Data Replikasi 1 Skenario 1 .....	63
Tabel 4.10	Akurasi Model ARIMAX-QR pada Data Simulasi Skenario 1.....	65
Tabel 4.11	Akurasi Ramalan Interval Model ARIMAX-QR pada Data Simulasi Skenario 1.....	67
Tabel 4.12	Bangkitan Data Simulasi untuk Pola Musiman Skenario 2.....	69
Tabel 4.13	Estimasi dan Signifikansi Parameter Model ARIMA Residual.....	71

Tabel 4.14 Pemenuhan Asumsi Model ARIMA Residual TSR Simulasi Skenario 2.....	72
Tabel 4.15 Hasil Pengujian Signifikansi Parameter Model ARIMA Skenario 2.....	74
Tabel 4.16 Estimasi Koefisien ARIMAX-QR Model 1 Data Dimulasi Skenario 2 Replikasi 1 .....	74
Tabel 4.17 Estimasi Parameter ARIMAX-QR Model 2 Residual Data Replikasi 1 Skenario 2 .....	76
Tabel 4.18 Estimasi Parameter Model Regresi Kuantil Residual Data Replikasi 1 Skenario 2 .....	78
Tabel 4.19 Akurasi Model ARIMAX-QR pada Data Simulasi Skenario 1 .....	81
Tabel 4.20 Akurasi Ramalan Interval Model ARIMAX-QR pada Data Simulasi Skenario 2.....	83
Tabel 4.21 Statistika Deskriptif (Miliar Rupiah).....	86
Tabel 4.22 Statistika Deskriptif <i>Inflow</i> dan <i>Outflow</i> per pecahan (Miliar Rupiah).....	92
Tabel 4.23 Hasil Pengujian Asumsi Residual Model Regresi <i>Time Series</i> .....	99
Tabel 4.24 Hasil Pengujian Asumsi Residual Model Regresi <i>Time Series Outflow</i> Pecahan Rp100.000 setelah ditambah Lag .....	102
Tabel 4.25 Hasil Pengujian Signifikansi Parameter Model <i>Time Series Regression</i> Data <i>Outflow</i> pecahan Rp100.000,00 .....	102
Tabel 4.26 Hasil Pengujian Signifikansi Parameter Model Regresi <i>Time Series Outflow</i> Pecahan Rp100.000 Menggunakan Backward Elimination .....	103
Tabel 4.27 Hasil Pengujian Asumsi Residual Model Regresi <i>Time Series Outflow</i> Pecahan Rp100.000 setelah Seleksi Variabel.....	104
Tabel 4.28 Hasil Pengujian Asumsi Residual Model Regresi <i>Time Series Transformasi Outflow</i> Pecahan Rp100.000 .....	106



Tabel 4.29 Hasil Pengujian Signifikansi Parameter Model Regresi <i>Time Series</i> Transformasi <i>Outflow</i> Pecahan Rp100.000 Menggunakan <i>Backward Elimination</i> ..	107
Tabel 4.30 Hasil Pengujian Asumsi Residual Model Regresi <i>Time Series</i> Transformasi <i>Outflow</i> Pecahan Rp100.000 setelah Signifikansi Parameter.....	108
Tabel 4.31 Hasil Pengujian Asumsi Residual Model Regresi <i>Time Series</i> Data <i>Inflow</i> dan <i>Outflow</i> setelah Signifikansi Parameter .....	109
Tabel 4.32 Nilai Kesalahan Ramalan Model <i>Time Series</i> Regression .....	114
Tabel 4.33 Hasil Pengujian Asumsi Residual Model ARIMAX Data <i>Outflow</i> pecahan Rp100.0000,00...	115
Tabel 4.34 Hasil Pengujian Signifikansi Parameter Model ARIMAX <i>Outflow</i> Pecahan Rp100.000 Menggunakan <i>Backward Elimination</i> .....	116
Tabel 4.35 Hasil Pengujian Asumsi Residual Model Variasi Kalender Data <i>Outflow</i> pecahan Rp100.000,00 setelah Pengujian Signifikansi Parameter .....	117
Tabel 4.36 Hasil Pengujian Asumsi Residual Model ARIMAX Transformasi <i>Outflow</i> Pecahan Rp100.000 .....	118
Tabel 4.37 Hasil Pengujian Signifikansi Parameter Model Regresi <i>Time Series</i> Transformasi <i>Outflow</i> Pecahan Rp100.000 Menggunakan <i>Backward Elimination</i> .....	119
Tabel 4.38 Hasil Pengujian Asumsi Residual Model ARIMAX Transformasi <i>Outflow</i> Pecahan Rp100.000 setelah Signifikansi Parameter.....	120
Tabel 4.39 Nilai Kesalahan Ramalan Model ARIMAX .....	124
Tabel 4.40 Model ARIMA Data <i>Inflow</i> dan <i>Outflow</i> Per Pecahan.....	126
Tabel 4.41 Uji Signifikansi Parameter Model ARIMA Data <i>Outflow</i> Pecahan Rp100.000,00 di Jawa Timur .....	127

Tabel 4.42 Uji Asumsi <i>White Noise</i> dan Distribusi Normal Residual ARIMA Data <i>Outflow</i> pecahan Rp100.000,00 .....	127
Tabel 4.43 Estimasi Koefisien Regresi Kuantil Data <i>Outflow</i> Pecahan Rp100.000,00 .....	128
Tabel 4.44 Nilai Kesalahan Ramalan Model ARIMAX-QR Model 1.....	132
Tabel 4.45 Nilai Estimasi Koefisien Parameter ARIMAX-QR Model 2.....	133
Tabel 4.46 Nilai Kesalahan Ramalan Model ARIMAX-QR Model 2.....	136
Tabel 4.47 Nilai Estimasi Koefisien Parameter ARIMAX-QR Model 3.....	137
Tabel 4.48 Nilai Kesalahan Ramalan Model ARIMAX-QR Model 3.....	140
Tabel 4.49 Nilai Estimasi Koefisien Parameter ARIMAX-QR Model 4.....	141
Tabel 4.50 Nilai Kesalahan Ramalan Model ARIMAX-QR Model 4.....	144
Tabel 4.51 Perbandingan Nilai Kesalahan Ramalan <i>Out-sample</i> tiap Metode .....	147
Tabel 4.52 Perbandingan Kebaikan Model Ramalan tiap Data.	153
Tabel 4.53 Ramalan <i>Outflow</i> Per Pecahan di Jawa Timur periode Januari 2017-Desember 2017 .....	161
Tabel 4.54 Ramalan <i>Inflow</i> Per Pecahan di Jawa Timur periode Januari 2017-Desember 2017 .....	163

## DAFTAR LAMPIRAN

Lampiran 1	Data <i>Inflow</i> Per Pecahan Uang Kertas di Jawa Timur.....	169
Lampiran 2	Data <i>Outflow</i> Per Pecahan Uang Kertas di Jawa Timur.....	170
Lampiran 3	<i>Syntax</i> Program SAS untuk Metode ARIMA ....	171
Lampiran 4	<i>Syntax</i> Program SAS untuk model <i>Time Series Regression Outflow</i> Pecahan Rp100.000,00 .....	172
Lampiran 5	<i>Syntax</i> Program SAS untuk Metode ARIMAX (ARIMA dengan Tambahan Efek Variasi Kalender) Data <i>Outflow</i> Rp100.000,00.....	173
Lampiran 6	Plot ACF dan PACF Dekomposisi ( <i>Time Series Regression</i> ) Data <i>Outflow</i> Per Pecahan.....	174
Lampiran 7	Plot ACF dan PACF Dekomposisi ( <i>Time Series Regression</i> ) Data <i>Inflow</i> Per Pecahan .....	177
Lampiran 8	<i>Output</i> Program SAS untuk model <i>Time Series Regression Outflow</i> Pecahan Rp100.000,00 .....	180
Lampiran 9	<i>Output</i> Program SAS untuk model <i>Time Series Regression Outflow</i> Pecahan Rp50.000,00 .....	181
Lampiran 10	<i>Output</i> Program SAS untuk model <i>Time Series Regression Outflow</i> Pecahan Rp20.000,00 .....	182
Lampiran 11	<i>Output</i> Program SAS untuk model <i>Time Series Regression Outflow</i> Pecahan Rp10.000,00 .....	183
Lampiran 12	<i>Output</i> Program SAS untuk model <i>Time Series Regression Outflow</i> Pecahan Rp5.000,00 .....	184
Lampiran 13	<i>Output</i> Program SAS untuk model <i>Time Series Regression Outflow</i> Pecahan Rp2.000,00 .....	185
Lampiran 14	<i>Output</i> Program SAS untuk model <i>Time Series Regression Outflow</i> Pecahan Rp1.000,00 .....	186
Lampiran 15	<i>Output</i> Program SAS untuk model <i>Time Series Regression Inflow</i> Pecahan Rp100.000,00.....	187
Lampiran 16	<i>Output</i> Program SAS untuk model <i>Time Series Regression Inflow</i> Pecahan Rp50.000,00.....	188
Lampiran 17	<i>Output</i> Program SAS untuk model <i>Time Series Regression Inflow</i> Pecahan Rp20.000,00.....	189

Lampiran 18	<i>Output Program SAS untuk model Time Series Regression Inflow Pecahan Rp10.000,00</i>	190
Lampiran 19	<i>Output Program SAS untuk model Time Series Regression Inflow Pecahan Rp5.000,00</i>	191
Lampiran 20	<i>Output Program SAS untuk model Time Series Regression Inflow Pecahan Rp2.000,00</i>	192
Lampiran 21	<i>Output Program SAS untuk model Time Series Regression Inflow Pecahan Rp1.000,00</i>	193
Lampiran 22	<i>Output Program SAS untuk model ARIMAX Outflow Pecahan Rp100.000,00</i>	194
Lampiran 23	<i>Output Program SAS untuk model ARIMAX Outflow Pecahan Rp50.000,00</i>	195
Lampiran 24	<i>Output Program SAS untuk model ARIMAX Outflow Pecahan Rp20.000,00</i>	196
Lampiran 25	<i>Output Program SAS untuk model ARIMAX Outflow Pecahan Rp10.000,00</i>	197
Lampiran 26	<i>Output Program SAS untuk model ARIMAX Outflow Pecahan Rp5.000,00</i>	198
Lampiran 27	<i>Output Program SAS untuk model ARIMAX Outflow Pecahan Rp2.000,00</i>	199
Lampiran 28	<i>Output Program SAS untuk model ARIMAX Outflow Pecahan Rp1.000,00</i>	200
Lampiran 29	<i>Output Program SAS untuk model ARIMAX Inflow Pecahan Rp100.000,00</i>	201
Lampiran 30	<i>Output Program SAS untuk model ARIMAX Inflow Pecahan Rp50.000,00</i>	202
Lampiran 31	<i>Output Program SAS untuk model ARIMAX Inflow Pecahan Rp20.000,00</i>	203
Lampiran 32	<i>Output Program SAS untuk model ARIMAX Inflow Pecahan Rp10.000,00</i>	204
Lampiran 33	<i>Output Program SAS untuk model ARIMAX Inflow Pecahan Rp5.000,00</i>	205
Lampiran 34	<i>Output Program SAS untuk model ARIMAX Inflow Pecahan Rp2.000,00</i>	206

Lampiran 35	<i>Output</i> Program SAS untuk model ARIMAX <i>Inflow</i> Pecahan Rp1.000,00.....	207
Lampiran 36	<i>Syntax</i> Metode ARIMAX-Quantile <i>Regression</i> Model 1 pada Data <i>Outflow</i> .....	208
Lampiran 37	<i>Syntax</i> Metode ARIMAX-Quantile <i>Regression</i> Model 1 pada Data <i>Inflow</i> .....	210
Lampiran 38	<i>Syntax</i> Metode ARIMAX-Quantile <i>Regression</i> Model 3 pada Data <i>Outflow</i> .....	212
Lampiran 39	<i>Syntax</i> Metode ARIMAX-Quantile <i>Regression</i> Model 3 pada Data <i>Inflow</i> .....	214
Lampiran 40	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Outflow</i> Rp100.000,00.....	216
Lampiran 41	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Outflow</i> Rp50.000,00.....	217
Lampiran 42	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Outflow</i> Rp20.000,00.....	218
Lampiran 43	Hasil Uji Signifikansi Parameter ARIMAX-QR	219
Lampiran 44	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Outflow</i> Rp5.000,00.....	220
Lampiran 45	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Outflow</i> Rp2.000,00.....	221
Lampiran 46	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Outflow</i> Rp1.000,00.....	222
Lampiran 47	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Inflow</i> Rp100.000,00 .....	223
Lampiran 48	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Inflow</i> Rp50.000,00 .....	224
Lampiran 49	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Inflow</i> Rp20.000,00 .....	225
Lampiran 50	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Inflow</i> Rp10.000,00 .....	226
Lampiran 51	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Inflow</i> Rp5.000,00 .....	227
Lampiran 52	Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Inflow</i> Rp2.000,00 .....	228

Lampiran 53 Hasil Uji Signifikansi Parameter ARIMAX-QR Model 1 pada Data <i>Inflow</i> Rp1.000,00.....	229
Lampiran 54 Surat Keterangan Data dari Bank Indonesia .....	232

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Tujuan utama Bank Indonesia sebagai bank sentral Republik Indonesia adalah mencapai dan memelihara kestabilan nilai rupiah. Dalam pelaksanaannya, Bank Indonesia memiliki kewenangan untuk melakukan kebijakan moneter melalui penetapan sasaran-sasaran moneter seperti uang beredar atau suku bunga (Bank Indonesia, 2016a). Jumlah uang yang beredar di masyarakat dapat menunjukkan pertumbuhan likuiditas perekonomian suatu negara, oleh karena itu, dibutuhkan suatu kebijakan yang tepat serta mampu membantu Bank Indonesia dalam menyusun perencanaan kebutuhan uang di Indonesia karena kesuksesan kinerja Bank Indonesia dapat tercermin pada terpenuhinya kebutuhan uang kartal masyarakat dalam jumlah nominal yang cukup, pecahan yang sesuai, tepat waktu dan dalam kondisi layak edar. Kelancaran transaksi pembayaran non-tunai dan terpenuhinya kebutuhan uang kartal masyarakat tersebut dicapai melalui serangkaian kebijakan Bank Indonesia (Bank Indonesia, 2013).

Uang kartal terdiri dari uang kertas dan uang logam yang merupakan alat pembayaran yang sah untuk transaksi masyarakat, termasuk di Indonesia. Di tengah pesatnya perkembangan inovasi instrumen pembayaran non tunai, uang kartal masih tetap memegang peranan penting dalam mendukung kelancaran transaksi pembayaran di masyarakat. Hal ini terlihat dari terus meningkatnya transaksi pembayaran tunai masyarakat yang salah satunya tercermin dari pertumbuhan jumlah uang kartal yang diedarkan maupun aliran uang kartal yang keluar dari Bank Indonesia ke perbankan dan masyarakat (*outflow*) dan aliran uang kartal yang masuk melalui Bank Indonesia. *Inflow* atau disebut dengan penyetoran uang adalah kegiatan bank melakukan penyetoran uang ke Bank Indonesia, sedangkan *outflow* atau disebut dengan penarikan uang adalah kegiatan bank melakukan penarikan uang

yang masih layak edar (ULE) dari Bank Indonesia (Bank Indonesia, 2013).

*Net inflow* transaksi uang kartal berarti jumlah penyetoran uang kartal ke Bank Indonesia lebih besar daripada jumlah penarikan uang kartal dari Bank Indonesia, sedangkan *net outflow* transaksi uang kartal berarti penyetoran uang rupiah (*inflow*) lebih kecil daripada penarikan uang rupiah (*outflow*). *Net inflow* yang cukup besar pada tahun 2015 tercatat di Jawa Barat, Jawa Tengah, DI Yogyakarta, dan Jawa Timur. Di keempat daerah tersebut, *net inflow* mencapai Rp72,9 triliun. Provinsi Jawa Timur merupakan provinsi dengan jumlah aliran uang masuk terbesar ketiga setelah DKI Jakarta dan Jawa Barat, dan merupakan jumlah aliran uang keluar terbesar kedua setelah DKI Jakarta (Bank Indonesia, 2016b). Jumlah uang beredar yang tinggi di Jawa Timur dimanfaatkan oleh oknum tidak bertanggung jawab untuk mengedarkan uang palsu. Temuan uang palsu di Jawa Timur terdiri atas berbagai pecahan rupiah, mulai 2.000 hingga 100.000 (Sholikhah, 2016). Oleh karena itu, dibutuhkan suatu kebijakan dari Bank Indonesia untuk mengendalikan aktifitas pengedaran uang.

Di Indonesia, kebanyakan aktifitas perekonomian dan bisnis mengikuti serta diamati berdasarkan penanggalan masehi, sedangkan pada kenyataannya Indonesia memiliki banyak hari khusus atau hari libur salah satunya seperti hari raya Idul Fitri yang terjadi tidak berdasarkan penanggalan masehi. Oleh karena itu, diperlukan suatu metode peramalan yang tepat dan dapat menangkap variasi dalam data. Apriliadara, Suhartono dan Prastyo (2016) menggunakan metode VARI-X dengan variasi kalender untuk meramalkan *inflow* dan *outflow*. Penelitian ini menggunakan *dummy* minggu terjadinya Hari Raya Idul Fitri sebagai *dummy* variasi kalender. Dari penelitian ini didapatkan bahwa metode VARI-X dengan efek variasi kalender mampu memodelkan dinamika *inflow* dan *outflow* di Indonesia yang dipengaruhi oleh Hari Raya Idul Fitri. Suhartono, Lee dan Prastyo (2015) menggunakan metode *Two level-ARIMAX* untuk meramalkan data *time series* mengenai penjualan pakaian pria dan wanita



dengan efek variasi kalender. Penelitian ini menghasilkan bahwa model dengan variasi kalender tersebut mampu menangkap pola dari efek Hari Raya Idul Fitri terhadap aktifitas penjualan pakaian. Model ini menghasilkan hasil akurasi yang lebih baik dibanding ARIMA maupun model *seasonal naïve*, baik berdasarkan kriteria *in-sample* maupun *out-sample*. Penelitian yang dilakukan oleh Hanim dan Suhartono (2015) juga menunjukkan bahwa model variasi kalender memberikan tingkat akurasi yang lebih baik untuk meramalkan *outflow* di Jawa Timur, DKI Jakarta dan Indonesia.

Variasi kebutuhan uang menyebabkan adanya volatilitas kebutuhan uang pada waktu-waktu tertentu yang mengindikasikan adanya heteroskedastisitas. Oleh karena itu diperlukan metode yang mampu menangkap kemungkinan terjadinya *underprediction* dan *overprediction* dari hasil ramalan. Salah satunya adalah menggunakan pendekatan regresi kuantil. Regresi kuantil (*Quantile Regression*) memperluas perhitungan nilai koefisien di berbagai kuantil, sehingga mampu memberikan gambaran yang lebih lengkap terhadap kondisi data. Selain itu, model peramalan kuantil juga memperkirakan koefisien dari model yang didapatkan (Huang & Yu, 2015). Li, Leng, Yang dan Yu (2016) meramalkan indeks saham multinasional dengan regresi kuantil. Dari penelitian tersebut diperoleh hasil bahwa peramalan menggunakan pendekatan regresi kuantil menghasilkan akurasi lebih baik dibanding metode *Ordinary Least Square* (OLS). Nilai ramalan yang dihasilkan regresi kuantil lebih banyak berada di dalam interval dibanding menggunakan metode OLS. Li, Xu, Li, Sun dan Dong (2012) menggunakan pendekatan regresi kuantil untuk menganalisis pergerakan harga produk agrikultural di Cina. Dari penelitian ini, diperoleh bahwa ramalan interval yang dihasilkan dari model regresi kuantil mampu mengikuti fluktuasi harga produk agrikultural di Cina.

Makridakis dan Hibon (2000) menyatakan bahwa berdasarkan hasil *M3-Competition*, metode gabungan secara rata-rata mampu meningkatkan akurasi ramalan dibanding metode individual, sehingga kini banyak peneliti yang menggunakan dan

mengembangkannya. Xu, Tsui, Jiang dan Guo (2016) menggunakan metode *hybrid* ARIMA-LR (*linear regression*) untuk meramalkan kedatangan pasien di suatu UGD di LiaoNing, China. Arunraj dan Ahrens (2015) meramalkan penjualan makanan (*daily food*) dengan metode *hybrid* SARIMAX-QR (*Quantile Regression*). Penelitian ini diterapkan dalam pemodelan dan peramalan data penjualan harian pisang di suatu toko di Jerman. Metode ini diawali dengan memodelkan data menggunakan model ARIMA, yang kemudian hasil ramalan *in-sample*nya diikutsertakan menjadi salah satu variabel prediktor dalam regresi *time series* antara data yang digunakan dengan variabel prediktor yang digunakan seperti *dummy* musiman, *dummy* variasi kalender, *dummy* iklim, dan lain-lain. Penelitian ini menggunakan kriteria *Forecast Value Added* (FVA) untuk membandingkan kebaikan model ramalan. Hasilnya menunjukkan bahwa model SARIMAX-MLR (*Multiple Linear Regression*) dan SARIMAX-QR menghasilkan akurasi ramalan yang lebih baik untuk data *out-sample* dibandingkan metode individu lainnya. Selain itu, metode ini memberikan interval prediksi yang lebih baik.

Penelitian ini menerapkan metode hibrida ARIMAX-QR untuk meramalkan *inflow* dan *outflow* pecahan uang kartal di Jawa Timur yang memiliki pola tren, musiman dan variasi kalender serta varians yang heterogen. Penelitian ini diharapkan mampu memberikan rekomendasi kepada Bank Indonesia khususnya KPw Jawa Timur dalam meramalkan *inflow* dan *outflow* pecahan uang kartal serta menjadi masukan dalam pembuatan kebijakan mengenai penguasaan uang.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang diatas, masalah pada penelitian ini berawal pada belum adanya metode terbaik yang digunakan untuk meramalkan *inflow* dan *outflow* oleh Bank Indonesia. Selain itu, diperlukan suatu metode yang mampu menggambarkan pola tren, musiman dan variasi kalender serta kasus heteroskedastisitas

dari suatu data, oleh karena itu, rumusan masalah pada penelitian ini adalah:

1. Bagaimana karakteristik serta pola dari data *inflow* dan *outflow* pecahan uang kartal di Jawa Timur?
2. Bagaimana model terbaik menggunakan metode *ARIMAX-Quantile Regression* yang sesuai untuk meramalkan *inflow* dan *outflow* pecahan uang kartal di Jawa Timur?
3. Bagaimana perbandingan kebaikan ramalan antara metode *ARIMAX-Quantile Regression* dan metode individu yang lain?

### 1.3 Tujuan Penelitian

Berdasarkan permasalahan yang diuraikan sebelumnya, maka tujuan yang ingin dicapai pada penelitian ini yaitu antara lain:

1. Untuk mengetahui karakteristik serta pola dari data *inflow* dan *outflow* pecahan uang kartal di Jawa Timur
2. Untuk mengetahui model terbaik menggunakan metode *ARIMAX-Quantile Regression* yang sesuai untuk meramalkan *inflow* dan *outflow* pecahan uang kartal di Jawa Timur.
3. Untuk mengetahui perbandingan serta mengevaluasi kebaikan ramalan antara metode *ARIMAX-Quantile Regression* dan metode individu yang lain.

### 1.4 Manfaat Penelitian

Hasil penelitian ini diharapkan mampu memberikan rekomendasi mengenai peramalan *inflow* dan *outflow* pecahan uang kartal yang lebih akurat bagi Bank Indonesia khususnya KPw Jawa Timur sebagai salah satu upaya pengambilan kebijakan dalam pengedaran uang sebagai pemenuhan fungsinya yaitu memenuhi kebutuhan uang masyarakat serta supaya pendistribusian uang dari Bank Indonesia lebih mampu memenuhi kebutuhan uang di masyarakat secara efektif dengan jumlah yang sesuai. Selain itu, bagi peneliti dapat mengaplikasikan ilmu statistika

dalam kehidupan sehari-hari terutama dalam peramalan *inflow* dan *outflow* uang kartal.

### **1.5 Batasan Masalah**

Batasan masalah pada penelitian ini yaitu data sekunder mengenai *inflow* dan *outflow* di Jawa Timur yaitu uang kertas pecahan Rp1.000,00; Rp2.000,00; Rp5.000,00; Rp10.000,00; Rp20.000,00; Rp50.000,00 dan Rp100.000,00 menggunakan data perbulan mulai Januari 2003 hingga Desember 2016. Metode individu yang digunakan pada penelitian ini adalah *time series regression* dan ARIMAX. Pemilihan model terbaik menggunakan prinsip *cross-validation* (Anders & Korn, 1999) yaitu model terbaik adalah yang memberikan ramalan yang paling akurat pada data *out-sample* (*testing*).

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Uang Kartal**

Uang adalah suatu benda yang dapat ditukarkan dengan benda lain, dapat digunakan untuk menilai benda lain, dapat disimpan, dan dapat digunakan sebagai alat pembayaran di waktu yang akan datang. Sebelum dikenalnya uang, masyarakat menggunakan sistem barter untuk melakukan transaksi satu sama lain. Pada perkembangannya, mulai digunakanlah beberapa benda yang diberlakukan sebagai uang, mulai dari batu, logam tembaga, perak dan emas. Pertama kali uang kertas digunakan sebagai pengganti sementara dari tembaga (awal abad ke-9 oleh Kaisar Cina). Masyarakat Barat mulai ikut mencetak uang kertas pada abad ke-17, yang kemudian diikuti pula oleh masyarakat Timur hingga saat ini (Solikin & Suseno, 2002).

Secara teori, faktor-faktor utama yang dapat diidentifikasi sebagai faktor yang mempengaruhi permintaan uang (Sigalingging, Setiawan & Sihaloho, 2004) antara lain:

1. Kecepatan Perputaran Uang (*velocity of circulation*)

Tingkat perputaran/perpindahan uang dari satu individu ke individu lain yang digunakan untuk kegiatan transaksi ekonomi di masyarakat akan mempengaruhi usia peredaran uang. Semakin besar tingkat perputaran uang akan memperpendek usia peredaran uang karena uang menjadi cepat lusuh. Umumnya denominasi pecahan kecil memiliki tingkat perputaran lebih cepat dibandingkan dengan pecahan besar.

2. Inflasi

Tingkat inflasi akan menyebabkan permintaan uang meningkat oleh karena harga barang cenderung lebih mahal sehingga untuk mendapatkan barang yang sama dibutuhkan lebih banyak uang. Di samping itu, kenaikan harga barang dapat menyebabkan kebutuhan masyarakat terhadap denominasi pecahan uang yang lebih besar semakin bertambah.

### 3. Pertumbuhan Produk Domestik Bruto (PDB)

PDB merupakan indikasi terjadinya pertumbuhan ekonomi. Umumnya pertumbuhan ekonomi disebabkan adanya peningkatan investasi dan transaksi kegiatan ekonomi. Apabila transaksi ekonomi meningkat dan menyebabkan pendapatan masyarakat juga meningkat, maka kebutuhan uang menjadi bertambah.

### 4. Kondisi Sistem Perbankan

Persepsi masyarakat terhadap kondisi perbankan dan atau sektor perbankan secara keseluruhan yang buruk, misalnya, isu penutupan bank yang dapat menimbulkan niat masyarakat melakukan penarikan uang tunai secara besar-besaran. Keadaan tersebut dapat menyebabkan permintaan uang meningkat secara tiba-tiba.

### 5. Pengaruh Musiman

Perilaku masyarakat terhadap permintaan uang pada waktu-waktu tertentu, misalnya, pada hari libur, hari raya keagamaan, menjelang waktu pergantian tahun, waktu penerimaan gaji karyawan pada akhir/awal bulan, dan menjelang akhir pekan. Pada waktu tersebut umumnya permintaan akan uang meningkat.

Transaksi penarikan uang rupiah (*outflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang keluar dari Bank Indonesia kepada perbankan dan masyarakat, terdiri dari penarikan bank umum, penarikan non-bank, kas keliling dalam rangka penukaran, penarikan dalam rangka kas titipan di bank umum, dan penarikan lainnya. Sedangkan transaksi penyetoran uang rupiah (*inflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang masuk dari perbankan dan masyarakat ke Bank Indonesia, terdiri dari setoran bank umum, setoran bank umum, setoran non-ban, kas keliling dalam rangka hasil penukaran, penyetoran dalam rangka kas titipan di bank umum, dan penyetoran lainnya. Selisih transaksi penarikan/penyetoran uang rupiah merupakan selisih antara transaksi penyetoran uang rupiah (*inflow*) dan transaksi penarikan uang rupiah (*outflow*) (Bank Indonesia, 2016c).

## 2.2 ACF dan PACF

*Auto Correlation Function* (ACF) merupakan suatu fungsi yang digunakan untuk menjelaskan korelasi antara  $Y_t$  dan  $Y_{t+k}$  dari suatu proses yang sama dan hanya terpisah oleh lag waktu ke- $k$ . ACF dicari dengan rumus sebagai berikut (Wei, 2006:10)

$$\rho_k = \frac{\text{Cov}(Y_t, Y_{t+k})}{\sqrt{\text{Var}(Y_t)}\sqrt{\text{Var}(Y_{t+k})}} = \frac{\gamma_k}{\gamma_0}, \quad (2.1)$$

dengan,

$\rho_k$  = autokorelasi pada lag ke- $k$

$\text{Cov}(Y_t, Y_{t+k}) = E(Y_t - \mu)(Y_{t+k} - \mu) = \gamma_k$

$\text{Var}(Y_t) = \text{Var}(Y_{t+k}) = \gamma_0$  .

*Partial Autocorrelation Function* (PACF) digunakan untuk mengukur korelasi antara  $Y_t$  dan  $Y_{t+k}$  setelah pengaruh variabel  $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$  dihilangkan. PACF dinyatakan dalam persamaan berikut (Wei, 2006: 11).

$$P_k = \text{Corr}(Y_t, Y_{t+k} \mid Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}),$$

atau,

$$P_k = \frac{\text{Cov}[(Y_t - \hat{Y}_t), (Y_{t+k} - \hat{Y}_{t+k})]}{\sqrt{\text{Var}(Y_t - \hat{Y}_t)}\sqrt{\text{Var}(Y_{t+k} - \hat{Y}_{t+k})}}, \quad (2.2)$$

dengan

$\hat{Y}_t = f(Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1})$   
 $= \beta_1 Y_{t+1} + \beta_2 Y_{t+2} + \dots + \beta_{k-1} Y_{t+k-1}$  ;  $\beta_i (1 \leq i \leq k-1)$   
 adalah *mean squared* koefisien regresi linier.

$\hat{Y}_{t+k} = f(Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1})$   
 $= \alpha_1 Y_{t+k-1} + \alpha_2 Y_{t+k-2} + \dots + \alpha_{k-1} Y_{t+1}$  ;  $\alpha_i (1 \leq i \leq k-1)$   
 adalah *mean squared* koefisien regresi linier.

## 2.3 Model Autoregressive Integrated Moving Average (ARIMA)

ARIMA merupakan salah satu model peramalan yang paling umum digunakan pada data *time series*. Model ARIMA memasukkan model *Autoregressive* (AR) dan model *Moving*

*Average* (MA) didalamnya, sehingga peramalan dengan model ARIMA terbagi menjadi empat yaitu model *Autoregressive* (AR), model *Moving Average* (MA) dan model *Autoregressive Moving Average* (ARMA) untuk data *time series* yang stasioner dan model *Autoregressive Integrated Moving Average* (ARIMA) untuk data *time series* yang tidak stasioner (Wei, 2006: 33-72).

Model AR merupakan suatu model yang menunjukkan hubungan antara suatu nilai pengamatan sekarang ( $Y_t$ ) dengan nilai pengamatan di waktu sebelumnya ( $Y_{t-k} : k = 1, 2, 3, \dots$ ) ditambah suatu nilai acak ( $a_t$ ) yang memenuhi asumsi *white noise* dan berdistribusi normal ( $0, \sigma_a^2$ ). Model MA merupakan suatu model yang cocok untuk medeskripsikan adanya hubungan antara suatu nilai pengamatan sekarang ( $Y_t$ ) dengan suatu nilai acak di waktu sebelumnya ( $a_{t-k} ; k = 1, 2, 3, \dots$ ). Gabungan dari model *Autoregressive* (AR) dan model *Moving Average* (MA) membentuk model *Autoregressive Moving Average* (ARMA). Persamaan umum dari model ARIMA ( $p, d, q$ )( $P, D, Q$ )<sup>S</sup> dan dituliskan dalam rumus sebagai berikut :

$$\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D\dot{Y}_t = \theta_q(B)\Theta_Q(B^S)a_t, \quad (2.3)$$

dengan,

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 \dots - \phi_p B^p),$$

$$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 \dots - \theta_q B^q),$$

$$\Phi_P(B^S) = (1 - \Phi_1 B^S - \Phi_2 B^{2S} \dots - \Phi_P B^{PS}),$$

$$\Theta_Q(B^S) = (1 - \Theta_1 B^S - \Theta_2 B^{2S} \dots - \Theta_Q B^{QS}),$$

dengan  $\dot{Y}_t = Y_t - \mu$ ,  $p$  merupakan orde model AR non musiman,  $q$  merupakan orde model MA non musiman,  $d$  orde *differencing* non musiman,  $P$  merupakan orde model AR musiman,  $Q$  merupakan orde model MA musiman,  $D$  orde *differencing* model non



musiman dan  $S$  periode musiman serta  $a_t$  merupakan nilai residual ke- $t$ .

Terdapat beberapa tahapan dalam peramalan dengan model ARIMA menggunakan prosedur Box-Jenkins antara lain identifikasi model, estimasi parameter, cek diagnosa, pemilihan model terbaik dan peramalan (Wei, 2016: 108-157).

### 2.3.1 Identifikasi Model

Tahapan pertama yang dilakukan adalah identifikasi model. Pada tahapan ini, dilakukan pengecekan kestasioneran data yang terbagi menjadi dua, yaitu stasioner dalam mean dan stasioner dalam varians. Pengecekan stasioneritas dapat menggunakan plot *time series*. Jika titik-titik pada plot *time series* menyebar disekitar garis sejajar dengan sumbu waktu ( $t$ ) maka dapat dikatakan bahwa data stasioner dalam *mean*.

- a. Jika belum stasioner dalam *mean*, maka dapat diatasi dengan melakukan *differencing* (Wei, 2006: 71). Proses *differencing* orde ke- $d$  dapat ditulis sebagai berikut.

$$\Delta^d Y_t = (1 - B)^d Y_t, \quad (2.4)$$

dengan  $Y_t$  merupakan pengamatan pada waktu ke- $t$  dan  $Y_{t-1}$  merupakan pengamatan pada satu waktu sebelumnya ( $t-1$ ).

- b. Jika data belum stasioner dalam varians dapat dilakukan penstabilan varians dengan Transformasi Box-Cox (Wei, 2006: 85) seperti pada persamaan (2.5).

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda}. \quad (2.5)$$

Berikut adalah tabel yang berisi macam-macam bentuk transformasi Box-Cox yang dapat digunakan sesuai nilai lamda ( $\lambda$ ) yang dimiliki.

**Tabel 2.1** Transformasi Box-Cox

Nilai lambda ( $\lambda$ )	Transformasi
-1,0	$1/Y_t$
-0,5	$1/\sqrt{Y_t}$
0,0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1,0	$Y_t$ (Tidak ditransformasi)

Selain menggunakan plot *time series*, dapat juga menggunakan plot ACF dan PACF untuk mengidentifikasi model. Berikut merupakan karakteristik dari ACF dan PACF secara teori yang dapat digunakan untuk menduga model (Bowerman & O'Connell, 1993: 572-574).

**Tabel 2. 2** Karakteristik ACF dan PACF untuk model ARIMA Non-Musiman

No.	Karakteristik ACF dan PACF	Operator Model ARIMA
1.	ACF signifikan pada lag 1,2, ..., $q$ dan <i>cuts off</i> setelah lag $q$ PACF turun cepat	$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 \dots - \theta_q B^q$
2.	ACF turun cepat PACF signifikan pada lag 1,2, ..., $p$ dan <i>cuts off</i> setelah lag $p$	$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 \dots - \phi_p B^p$
3.	ACF signifikan pada lag 1,2, ..., $q$ dan <i>cuts off</i> setelah lag $q$ PACF signifikan pada lag 1,2, ..., $p$ dan <i>cuts off</i> setelah lag $p$	$\theta_q(B)$ atau $\phi_p(B)$ Apabila plot ACF <i>cuts off</i> lebih tajam maka operator yang digunakan adalah $\theta_q(B)$ , Apabila plot PACF <i>cuts off</i> lebih tajam operator yang digunakan adalah $\phi_p(B)$ Apabila <i>cuts off</i> tajam di keduanya maka dapat digunakan operator $\theta_q(B)$ atau $\phi_p(B)$ sebagai dugaan awal.

**Tabel 2.2** Karakteristik ACF dan PACF untuk model ARIMA Non-Musiman (lanjutan)

No.	Karakteristik ACF dan PACF	Operator Model ARIMA
4.	ACF turun cepat PACF turun cepat	$\theta_q(B)$ dan $\phi_p(B)$
5.	ACF tidak signifikan pada lag berapapun PACF tidak signifikan pada lag berapapun	Tidak ada operator non-musiman

Karakteristik dari ACF dan PACF secara teori yang dapat digunakan untuk menduga model ARIMA musiman disajikan dalam Tabel 2.3 berikut.

**Tabel 2.3** Karakteristik ACF dan PACF untuk model ARIMA Musiman

No.	Karakteristik ACF dan PACF	Operator Model Musiman
1.	ACF signifikan pada lag $S, 2S, \dots, QS$ dan <i>cuts off</i> setelah lag $QS$ PACF turun cepat	$\Theta_Q(B^S) = 1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS}$
2.	ACF turun cepat PACF signifikan pada lag $S, 2S, \dots, PS$ dan <i>cuts off</i> setelah lag $PS$	$\Phi_P(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS}$
3.	ACF signifikan pada lag $S, 2S, \dots, QS$ dan <i>cuts off</i> setelah lag $QS$ PACF signifikan pada lag $S, 2S, \dots, PS$ dan <i>cuts off</i> setelah lag $PS$	$\Theta_Q(B^S)$ atau $\Phi_P(B^S)$ Apabila plot ACF <i>cuts off</i> lebih tajam maka operator yang digunakan adalah $\Theta_Q(B^S)$ , Apabila plot PACF <i>cuts off</i> lebih tajam maka operator yang digunakan adalah $\Phi_P(B^S)$ . Apabila <i>cuts off</i> tajam di keduanya maka dapat digunakan operator $\Theta_Q(B^S)$ atau $\Phi_P(B^S)$ sebagai dugaan awal.

**Tabel 2.3** Karakteristik ACF dan PACF untuk model ARIMA Musiman  
(lanjutan)

No.	Karakteristik ACF dan PACF	Operator Model ARIMA
4.	ACF turun cepat pada lag-lag musiman PACF turun cepat pada lag-lag musiman	$\Theta_Q(B^S)$ dan $\Phi_P(B^S)$
5.	ACF tidak signifikan pada lag musiman berapapun PACF tidak signifikan pada lag musiman berapapun	Tidak ada operator musiman

### 2.3.2 Estimasi dan Pengujian Parameter

Salah satu metode yang umum digunakan untuk mengestimasi parameter adalah *Conditional Least Square* (CLS). Estimasi parameter model AR(1) menggunakan CLS (Cryer & Chan, 2008: 154-156) adalah sebagai berikut,

$$\dot{Y}_t = \phi \dot{Y}_{t-1} + a_t, \quad (2.6)$$

$$Y_t - \mu = \phi(Y_{t-1} - \mu) + a_t. \quad (2.7)$$

Persamaan (2.7) dapat dilihat sebagai suatu persamaan regresi dengan prediktor  $Y_{t-1}$  dengan respon  $Y_t$ . Estimasi *least square* meminimumkan nilai jumlah kuadrat error,

$$(Y_t - \mu) - \phi(Y_{t-1} - \mu) = a_t, \quad (2.8)$$

dengan nilai SSE sebagai berikut,

$$S(\phi, \mu) = \sum_{t=2}^n [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2. \quad (2.9)$$

Sesuai dengan prinsip *least square*, untuk mengestimasi nilai  $\phi$  dan  $\mu$  maka perlu meminimumkan  $S(\phi, \mu)$  dengan  $\frac{\partial S}{\partial \mu} = 0$  sebagai berikut,

$$\frac{\partial S}{\partial \mu} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi(Y_{t-1} - \mu)](-1 + \phi) = 0, \quad (2.10)$$

diperoleh solusi untuk  $\mu$ ,

$$\mu = \frac{1}{(n-1)(1-\phi)} \left[ \sum_{t=2}^n Y_t - \phi \sum_{t=2}^n Y_{t-1} \right], \quad (2.11)$$

dan untuk  $n$  besar,

$$\frac{1}{n-1} \sum_{t=2}^n Y_t \approx \frac{1}{n-1} \sum_{t=2}^n Y_{t-1} \approx \bar{Y}, \quad (2.12)$$

sehingga diperoleh nilai estimasi  $\mu$  dengan suatu nilai  $\phi$  tertentu adalah sebagai berikut,

$$\hat{\mu} = \frac{1}{(1-\phi)} [\bar{Y} - \phi \bar{Y}] = \bar{Y}, \quad (2.13)$$

untuk nilai estimasi  $\phi$  dengan meminimumkan  $S(\phi, \bar{Y})$  dengan

$$\frac{\partial S(\phi, \bar{Y})}{\partial \mu} = 0 \text{ dan didapatkan,}$$

$$\hat{\phi} = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2}. \quad (2.14)$$

Setelah dilakukan estimasi parameter maka langkah selanjutnya adalah melakukan uji signifikansi parameter. Berikut merupakan pengujian signifikansi parameter AR dengan hipotesis,  $H_0 : \phi_i = 0$  (parameter AR tidak signifikan)

$H_1 : \phi_i \neq 0$  dimana  $i = 1, 2, \dots, p$  (parameter AR tidak signifikan).

Statistik uji yang digunakan dalam pengujian signifikansi parameter adalah sebagai berikut,

$$t_{hitung} = \frac{\hat{\phi}_i}{se(\hat{\phi}_i)} . \quad (2.15)$$

Tolak  $H_0$  jika  $|t_{hitung}| > t_{\alpha/2, (n-p)}$  atau  $p\text{-value} < \alpha$  yang berarti parameter AR tidak signifikan.

### 2.3.3 Cek Diagnosa

Tahapan cek diagnosa merupakan tahapan untuk menguji apakah model sudah sesuai. Pada tahapan ini akan dilakukan pengecekan apakah residual ( $a_t$ ) sudah memenuhi asumsi kebaikan model yaitu memenuhi asumsi *white noise* dan berdistribusi normal  $(0, \sigma_a^2)$  (Wei, 2006: 152-153). Untuk mengecek apakah residual memenuhi asumsi *white noise* dapat menggunakan plot ACF dan PACF yaitu dengan ditunjukkan dengan residual tidak membentuk suatu pola tertentu atau menunjukkan nilai yang tidak signifikan secara statistik.

Residual yang *white noise* adalah residual yang memenuhi asumsi independen dan memiliki varians yang homogen. Pengujian independensi residual yang digunakan adalah *portmanteau test*. Uji ini menggunakan semua nilai ACF dari residual dengan hipotesis sebagai berikut,

$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$  (residual independen)

$H_1 : \text{min terdapat satu } \rho_k \neq 0, k = 1, 2, \dots, K$

dengan  $\rho_1, \rho_2, \dots, \rho_K$  merupakan autokorelasi hingga lag ke- $K$ . Statistik uji yang digunakan adalah Ljung-Box dengan rumus yang ditulis sebagai berikut,

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2, \quad (2.16)$$

dengan,

$Q$  : statistik uji Ljung-Box,

$n$  : jumlah observasi,

$\hat{\rho}_k$  : dugaan autokorelasi residual pada lag ke- $k$ .

Residual memenuhi asumsi independen jika gagal tolak  $H_0$  yaitu apabila nilai  $Q < \chi_{\alpha, df}^2$  atau  $p\text{-value} > \alpha$ .

Pengujian heteroskedastisitas residual atau uji efek ARCH pada data *time series* menggunakan *LM test* (Wei, 2006: 369-370). Misalkan  $\hat{u}_t$  merupakan suatu deret *noise* yang akan diuji variansnya, dengan  $\hat{u}_t^2$  mengikuti model AR( $s$ ) dengan model berikut,

$$\hat{u}_t^2 = \theta_0 + \theta_1 \hat{u}_{t-1}^2 + \theta_2 \hat{u}_{t-2}^2 + \dots + \theta_s \hat{u}_{t-s}^2 + a_t, \quad (2.17)$$

untuk  $t = s + 1, s + 2, \dots, n$ . Hipotesis pengujian efek ARCH adalah sebagai berikut,

$H_0 : \theta_1 = \theta_2 = \dots = \theta_s = 0$  (tidak mengandung efek ARCH)

$H_1 : \text{min terdapat satu } \theta_j \neq 0, j = 1, 2, \dots, s$ .

Statistik uji *Lagrange Multiplier* adalah,

$$LM = (n - s)R^2, \quad (2.18)$$

dengan,

$$R^2 = \frac{SSR}{SST}.$$

*Sum square of regression* (SSR) dan *sum square total* (SST) diperoleh dari regresi antara  $\hat{u}_t^2$  dengan  $\hat{u}_{t-1}^2, \hat{u}_{t-2}^2, \dots, \hat{u}_{t-s}^2$ . Tolak  $H_0$  apabila  $LM > \chi^2(s)$  yang berarti terdapat kasus heteroskedastisitas (varians tidak homogen) pada residual.

Pengujian asumsi residual distribusi normal menggunakan uji *Kolmogorov-Smirnov* dengan hipotesis sebagai berikut,

$H_0 : F_n(a_t) = F_0(a_t)$

(residual mengikuti asumsi berdistribusi normal)

$H_1 : F_n(a_t) \neq F_0(a_t)$

(residual tidak mengikuti asumsi berdistribusi normal)

dengan statistik uji,

$$D = \sup_x |F_n(a_t) - F_0(a_t)|, \quad (2.19)$$

dengan,

$F_n(a_t)$  : fungsi peluang kumulatif yang dihitung dari residual,

$F_0(a_t)$  : fungsi peluang kumulatif distribusi normal atau fungsi yang dihipotesiskan,

$\sup_x$  : nilai supremum semua  $x$  dari  $|F_n(a_t) - F_0(a_t)|$ .

Statistik uji  $D$  menghasilkan keputusan gagal tolak  $H_0$  atau residual memenuhi asumsi distribusi normal jika  $D < D_{(1-\alpha, n)}$  atau nilai  $p$ -value lebih dari  $\alpha$  (Daniel, 1989: 343-345).

### 2.3.4 Pemilihan Model Terbaik

Pemilihan model terbaik yang digunakan adalah berdasarkan kebaikan model (akurasi ramalan) di *out-sample*. Pemilihan model *out-sample* terbaik menggunakan nilai RMSE yaitu pemilihan model terbaik berdasarkan *error* peramalan (Wei, 2006: 181). Dimisalkan suatu ramalan titik  $l$ -waktu ke depan maka,

$$e_l = Y_{n+l} - \hat{Y}_n(l). \quad (2.20)$$

Nilai RMSE dapat dihitung dengan rumus sebagai berikut,

$$RMSE = \sqrt{\frac{1}{M} \sum_{l=1}^M e_l^2}, \quad (2.21)$$

dengan  $n$  jumlah observasi pada data *in-sample* dan  $l = 1, 2, \dots, M$ .

Evaluasi model yang menghasilkan ramalan interval juga akan dilakukan berdasarkan kebaikan ramalan interval yang terbentuk. Salah satu kriteria yang banyak digunakan adalah menentukan akurasi model berdasarkan persentase data *testing* yang masuk di dalam suatu ramalan interval tertentu (Taylor, 2000). Model yang memiliki akurasi yang lebih baik adalah model yang memiliki persentase data *testing* yang termuat di dalam interval tertentu.



## 2.4 Time Series Regression

Model regresi merupakan model statistik yang paling sering digunakan untuk mengetahui hubungan antara variabel respon dan variabel prediktor. Regresi untuk data *time series* dapat menggunakan pendekatan linier, dengan bentuk umum yang hampir sama dengan model regresi pada umumnya. Model umum regresi adalah sebagai berikut,

$$Y_t = \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_k X_{k,t} + a_t, \quad (2.22)$$

dengan  $Y_t$  merupakan variabel respon yang diasumsikan dipengaruhi oleh variabel prediktor  $X_t$ . Pada *time series regression*, model dapat dipengaruhi oleh tren, pola musiman, dan variasi kalender (Suhartono, Lee & Hamzah, 2010). Pola tren pada data menggunakan variabel *dummy*  $t$  dengan  $t=1,2,\dots,n$ . Apabila terdapat  $S$  musiman (bulanan) per tahun pada data, maka variabel *dummy* untuk faktor musiman ini adalah  $M_{1,t}, M_{2,t}, \dots, M_{12,t}$  (terdapat 12 bulan dalam satu tahun periode). Pada model *time series regression* dengan efek variasi kalender yaitu efek Hari Raya Idul Fitri menggunakan variabel *dummy*  $V_{1,t}, V_{2,t}, V_{3,t}, V_{4,t}$  untuk menunjukkan minggu ke-1 hingga minggu ke-4 pada bulan terjadinya Idul Fitri,  $V_{1,t-1}, V_{2,t-1}, V_{3,t-1}, V_{4,t-1}$  menunjukkan variabel *dummy* untuk minggu ke-1 hingga minggu ke-4 pada satu bulan sebelum Idul Fitri dan  $V_{1,t+1}, V_{2,t+1}, V_{3,t+1}, V_{4,t+1}$  untuk *dummy* minggu ke-1 hingga minggu ke-4 pada satu bulan setelah Idul Fitri. Pada penelitian ini menggunakan prediktor pola tren, musiman dan variasi kalender sehingga model regresi *time series* yang terbentuk untuk data *inflow* adalah,

$$Y_t = \beta_1 t + \sum_{i=1}^{12} \gamma_i M_{i,t} + \sum_{j=1}^4 \delta_j V_{j,t} + \sum_{j=1}^4 \alpha_j V_{j,t+1} + a_t, \quad (2.23)$$

dan untuk data *outflow* adalah,

$$Y_t = \beta_1 t + \sum_{i=1}^{12} \gamma_i M_{i,t} + \sum_{j=1}^4 \delta_j V_{j,t} + \sum_{j=1}^4 \omega_j V_{j,t-1} + a_t, \quad (2.24)$$

dengan  $a_t$  adalah *error* yang telah memenuhi asumsi *white noise*.

Apabila *error* belum memenuhi asumsi *white noise* maka lag  $Y_t$  digunakan sebagai tambahan variabel prediktor. Pemilihan lag dapat ditentukan berdasarkan plot ACF dan PACF (Lee, Suhartono, & Hamzah, 2010). Berikut adalah tahapan yang dilakukan pada *time series regression*.

a. Estimasi Parameter

Estimasi parameter menggunakan *Ordinary Least Square* (OLS) meminimumkan jumlah kuadrat penyimpangan atau error nilai-nilai observasi terhadap rata-ratanya (*mean*). Persamaan model regresi linear sederhana adalah sebagai berikut (Draper & Smith, 1998: 135-136).

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad (2.25)$$

dengan  $\boldsymbol{\beta}$  merupakan vektor yang berisi parameter yang akan di estimasi dari model. Persamaan (2.26) kemudian diturunkan terhadap masing-masing parameternya yaitu sehingga didapatkan estimasi parameter sebagai berikut,

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}. \quad (2.26)$$

b. Uji Signifikansi Parameter

Pengujian signifikansi parameter dilakukan secara parsial. Pengujian secara parsial merupakan pengujian yang dapat dilakukan sebanyak parameter dalam model regresi (Draper & Smith, 1998: 36-37). Berikut hipotesis pengujian parameternya,

$$H_0 : \beta_j = 0$$

$$H_1 : \beta_j \neq 0, j = 1, 2, \dots, k.$$

Untuk menguji signifikansi parameter dapat dihitung menggunakan statistik uji  $t$  berikut,

$$t_{hitung} = \frac{\hat{\beta}_j}{se(\hat{\beta}_j)} \quad (2.27)$$

Nilai statistik uji  $t$  dikatakan tolak  $H_0$  jika  $|t_{hitung}| > t_{\alpha/2, n-k}$  atau tolak  $H_0$  jika  $p$ -value kurang dari nilai  $\alpha$  yang digunakan, dengan  $n$  adalah ukuran sampel dan  $k$  adalah jumlah koefisien regresi yang terbentuk.

## 2.5 Model Autoregressive Integrated Moving Average with Exogeneous Variable (ARIMAX)

Hari Raya Idul Fitri terjadi berdasarkan penanggalan kalender Islam, sehingga terjadi pergeseran maju setiap tahunnya. Dengan adanya periode yang tidak tetap ini maka model variasi kalender diterapkan pada penelitian ini karena Hari Raya Idul Fitri diduga mengakibatkan jumlah uang yang beredar di masyarakat meningkat. Salah satu jenis model variasi kalender adalah model variasi kalender dengan metode ARIMAX. Model ini merupakan model *time series* yang digunakan untuk meramalkan data berdasarkan pola musiman dengan periode bervariasi (Karomah & Suhartono, 2014). Model variasi kalender pada penelitian ini dilakukan dengan menambahkan variabel *dummy* sebagai efek variasi kalender sebagai berikut.

$$Y_t = \beta_1 t + \beta_2 D_{1,t} + \beta_3 D_{2,t} + \beta_4 t D_{1,t} + \beta_5 t D_{2,t} + \gamma_1 M_{1,t} + \gamma_2 M_{2,t} + \dots + \gamma_{12} M_{12,t} + \delta_1 V_{1,t} + \dots + \delta_4 V_{4,t} + \alpha_1 V_{1,t+1} + \dots + \alpha_4 V_{4,t+1} + N_t \quad (2.28)$$

dengan,

$$N_t = \frac{\theta_q(B)}{\phi_p(B)} a_t, \quad (2.29)$$

dan,

$t, D_{1,t}, D_{2,t}, tD_{1,t}, tD_{2,t}$  : variabel *dummy* tren dan kebijakan BI,

$M_{1,t}, M_{2,t}, \dots, M_{12,t}$  : variabel *dummy* bulan,

$V_{1,t}, V_{2,t}, \dots, V_{4,t+1}$  : variabel *dummy* variasi kalender,

$\beta_1, \beta_2, \dots, \alpha_4$  : koefisien regresi,

$(p, q)$  : orde model ARIMA dari residual *time series regression* antara variabel respon dan prediktor.

## 2.6 Quantile Regression

Kuartil adalah suatu teknik pembagian sekelompok data yang telah diurutkan menjadi empat bagian yang sama. Apabila sekelompok data dibagi menjadi sepuluh bagian yang sama maka disebut desil, sedangkan apabila dibagi menjadi seratus bagian yang sama disebut persentil. Kuantil adalah suatu teknik pembagian sekelompok data kepada beberapa bagian yang sama, setelah data diurutkan dari yang paling kecil atau paling besar. Pada data tunggal, letak kuartil ke- $i$  adalah,

$$w_i = \frac{i(n+1)}{4}, \quad i=1,2,3, \quad (2.30)$$

dengan  $n$  merupakan jumlah data. Nilai kuartil ke- $i$  data tunggal dapat dihitung dengan rumus sebagai berikut.

$$Q_i = x_{(a)} + b(x_{(a+1)} - x_{(a)}) \quad (2.31)$$

dengan,

$Q_i$  : kuartil ke- $i$  dimana  $i=1,2$ , dan  $3$ ,

$a$  : nilai integer dari  $w$ ,

$b$  : komponen fraksional (pecahan) dari  $w$ ,

$x_{(a)}$  : data ke- $a$ .

Dengan menggunakan persamaan 2.31, maka dengan cara yang sama dilakukan untuk menghitung nilai kuantil dari suatu data tunggal dengan letak kuantil ke- $j$  adalah sebagai berikut.

$$w_j = \frac{j(n+1)}{100}, \quad j=1,2,...,100. \quad (2.32)$$

Nilai kuartil ke-2 ( $Q_2$ ) sama dengan nilai kuantil 50% atau bisa disebut juga sebagai median (nilai tengah). Pada data kelompok, kuartil ke- $i$  data kelompok dapat dihitung dengan rumus sebagai berikut.

$$Q_i = b_i + \left( \frac{\frac{i}{4}n - f_{k_{ii}}}{f_i} \right) l, \quad (2.33)$$

dengan,

$Q_i$  : kuartil ke- $i$ ,

$n$  : banyak data,

$b_i$  : batas bawah interval kelas kuartil ke- $i$ ,

$f_i$  : frekuensi kelas kuartil ke- $i$ ,

$f_{k_{ii}}$  : frekuensi kumulatif kelas sebelum kelas kuartil ke- $i$ ,

$l$  : lebar interval kelas.

Nilai kuantil ke- $j$  dari suatu data kelompok dapat dihitung dengan rumus sebagai berikut.

$$Q_j = b_j + \left( \frac{\frac{j}{100}n - f_{k_{jj}}}{f_j} \right) l, \quad (2.34)$$

dengan,

$Q_j$  : Kuantil ke- $j$ ,

$b_j$  : batas bawah interval kelas kuantil ke- $j$ ,

$f_j$  : frekuensi kelas kuantil ke- $j$ ,

$f_{k_{jj}}$  : frekuensi kumulatif kelas sebelum kelas kuantil ke- $j$ .


Pada teknik pembagian data dengan kuartil, desil atau persentil, data telah diketahui atau dapat diasumsikan berdistribusi normal, sedangkan apabila pembagian data menggunakan teknik kuantil, pembagian dari tiap-tiap kuantil disesuaikan dengan distribusi dari data tersebut. Misal  $X$  memiliki fungsi distribusi kumulatif sebagai berikut:

$$F(x) = P(X \leq x),$$

maka kuantil ke-  $\tau$  dari  $X$  adalah

$$Q(\tau) = F^{-1}(\tau) = \inf\{x : F(x) \geq \tau\}, \quad (2.35)$$

dengan  $0 < \tau < 1$ . Median  $F^{-1}(0,5)$  berperan sebagai peran sentral (Koenker, 2006: 5). Nilai kuantil ke-  $\tau$  merupakan invers dari fungsi distribusi kumulatif (*Cumulative Distribution Function*) dari data. Diberikan ilustrasi untuk menghitung nilai kuantil 0,05 pada distribusi normal standar. Pada Gambar 2.1 ditunjukkan bahwa nilai kuantil 0,05 dari distribusi normal standar adalah sebesar -1,645.



**Gambar 2.1** Ilustrasi Menghitung Nilai Kuantil dari Distribusi Normal Standar

Regresi kuantil merupakan suatu pendekatan dalam analisis regresi yang dikenalkan oleh Koenker dan Bassett (1978). Regresi kuantil berguna apabila distribusi data tidak homogen (*heterogenous*), tidak simetris, terdapat ekor pada sebaran (*long tails*) (Koenker, 2005). Model regresi konvensional seperti OLS dapat memberikan informasi yang paling relevan untuk pengamatan yang berada di sekitar rata-rata, namun regresi kuantil memberikan fleksibilitas yang lebih besar untuk mengidentifikasi hubungan yang berbeda pada bagian yang berbeda dari distribusi variabel dependen. Keuntungan lain dari regresi kuantil dibanding regresi OLS adalah bahwa estimasi regresi kuantil lebih *robust* terhadap *outlier*, yang memberikan keunggulan saat menangani heteroskedastisitas dan *skewness* serta tidak memerlukan pengujian asumsi residual.

Heteroskedastisitas atau variasi yang tidak sama menyiratkan bahwa terdapat lebih dari satu *slope* yang menggambarkan hubungan antara variabel respon dan variabel prediktor yang diukur pada subset dari faktor-faktor ini. Regresi kuantil memperkirakan beberapa tingkat perubahan (*slope*) dari respon minimum ke maksimum, memberikan gambaran yang lebih lengkap tentang hubungan antara variabel yang terkadang terlewat oleh regresi lainnya (Cade & Noon, 2003).

Pendekatan regresi kuantil menduga berbagai fungsi kuantil dari suatu distribusi  $Y$  sebagai fungsi dari  $X$ . Penggunaan metode regresi ini dilakukan dengan pembagian atau pemisahan data menjadi beberapa kelompok yang diduga mempunyai perbedaan nilai dugaan pada kuantil-kuantil tersebut. Estimasi variabel respon pada regresi kuantil menggunakan nilai kuantil ke-  $\tau$  dari  $Y$  dengan syarat suatu  $X$  tertentu atau dapat dituliskan  $Q_\tau(Y|X)$ . Hal inilah yang membedakan regresi kuantil dengan regresi klasik OLS, dimana pada regresi klasik nilai estimasi variabel responnya menggunakan ekspektasi dari  $Y$  dengan syarat suatu  $X$  tertentu,  $E(Y|X)$ . Model dari persamaan regresi kuantil yang terdiri dari satu variabel independen  $Y$  dan dua atau lebih variabel independen  $X$  dapat ditulis dalam bentuk matriks berikut.

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta}(\tau) + \mathbf{u}, \quad (2.36)$$

atau,

$$Q_\tau(Y|X) = \mathbf{X}\boldsymbol{\beta}(\tau) + \mathbf{u},$$

dengan,

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \mathbf{X} = \begin{bmatrix} x_{11} & x_{21} & \dots & x_{p1} \\ x_{12} & x_{22} & \dots & x_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1n} & x_{2n} & \dots & x_{pn} \end{bmatrix}, \boldsymbol{\beta}(\tau) = \begin{bmatrix} \beta_1(\tau) \\ \beta_2(\tau) \\ \vdots \\ \beta_p(\tau) \end{bmatrix}, \mathbf{u} = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix}$$

dengan,

$\mathbf{y}$  : Vektor berukuran  $n \times 1$  dari variabel respon

- X** : Matriks berukuran  $n \times p$  dari variabel prediktor  
 **$\beta(\tau)$**  : Vektor berukuran  $n \times 1$  dari koefisien regresi kuantil  
pada  $\tau$  ( $0 < \tau < 1$ )  
**u** : Vektor berukuran  $n \times 1$  dari error.

Regresi kuantil memperluas model regresi median pada semua kuantil dan meminimalkan fungsi objektif kuantil (Koenker & Basset, 1978) dengan pembobot  $\tau$  untuk *error* positif dan pembobot  $(1 - \tau)$  untuk *error* negatif sehingga estimasi parameter pada regresi kuantil ke-  $\tau$  dapat dinyatakan dalam bentuk berikut,

$$\hat{\beta}(\tau) = \min_{\beta \in \mathbb{R}^p} \left[ \sum_{y \in \{t: y \geq \mathbf{X}\beta\}} \tau |y - \mathbf{X}\beta(\tau)| + \sum_{y \in \{t: y < \mathbf{X}\beta\}} (1 - \tau) |y - \mathbf{X}\beta(\tau)| \right] \quad (2.37)$$

dengan  $\hat{\beta}(\tau)$  merupakan koefisien regresi pada kuantil-  $\tau$  . Estimasi parameter dengan regresi kuantil ke-  $\tau$  dapat dituliskan sebagai berikut,

$$\hat{\beta}(\tau) = \min_{\beta \in \mathbb{R}^p} \sum_{t=1}^n \rho_{\tau}(\mathbf{u}) \quad (2.38)$$


dengan  $\rho_{\tau}(\mathbf{u}) = [\rho_{\tau}(u_1), \rho_{\tau}(u_2), \dots, \rho_{\tau}(u_2)]' \cdot \rho_{\tau}(u_t)$  merupakan *loss function* dari regresi kuantil yaitu,

$$\rho_{\tau}(u_t) = u_t(\tau - I(u_t < 0)) = \begin{cases} \tau u_t & , u_t \geq 0 \\ (\tau - 1)u & , u_t < 0 \end{cases} ,$$

Regresi rata-rata klasik (*classical mean regression*) menggunakan estimasi titik untuk mengidentifikasi signifikansi variabel terhadap respon. Pendekatan regresi kuantil dapat digunakan untuk membangun prediksi interval, menyelidiki perilaku dari variabel respon pada kuantil yang berbeda dengan memperhatikan variabel independen dapat mengakibatkan kesimpulan yang berbeda dibandingkan dengan memeriksa hanya rata-rata variabel respon. Berikut adalah ilustrasi dari pemodelan menggunakan regresi OLS dan regresi kuantil pada data yang



memiliki varians homogen dengan *error* simetris (a) serta pada data yang memiliki varians yang heterogen dengan *error* simetris (b).



**Gambar 2.2** Ilustrasi Estimasi Parameter Regresi Klasik OLS dan Regresi Kuantil

Pada Gambar 2.2(a) ditunjukkan bahwa apabila data mengalami homoskedastisitas (varians yang sama) atau simetris, nilai rata-rata (*mean*) dan median cenderung sama atau tidak jauh berbeda, sehingga penggunaan regresi OLS maupun regresi kuantil dapat digunakan untuk memodelkan data yang tidak mengalami heteroskedastisitas. Pada Gambar 2.2(b) ditunjukkan bahwa data mengalami heteroskedastisitas (varians yang tidak homogen) namun memiliki *error* yang simetris, sehingga untuk ramalan titik menggunakan *mean* maupun median akan cenderung sama, namun hal yang berbeda ditunjukkan pada ramalan interval yang dihasilkan oleh regresi klasik dan regresi kuantil, dimana pada regresi klasik, batas atas dan batas bawahnya memiliki interval atau jarak yang sama terhadap nilai ramalan titiknya, sedangkan pada regresi kuantil nilai ramalan intervalnya mampu mengikuti pola data yang memiliki varians yang heterogen. Hal inilah yang menunjukkan keunggulan regresi kuantil dibanding regresi klasik untuk kasus data yang mengalami heteroskedastisitas.

Apabila suatu nilai ramalan atau nilai ke depan dari data *time series* tidak diketahui, maka nilai-nilai tersebut dapat dianggap sebagai suatu variabel random dan memiliki distribusi tertentu yang bisa disebut sebagai “*forecast distribution*”. Ramalan kuantil merupakan suatu kuantil dari *forecast distribution* tersebut. Pada ramalan titik, biasa digunakan nilai rata-rata atau median dari *forecast distribution*, sedangkan ramalan interval adalah suatu prediksi interval atau cakupan probabilitas dari distribusi tersebut. Misalnya jika diasumsikan suatu nilai ramalan adalah berdistribusi normal maka ramalan interval 95% ditentukan oleh kuantil 2,5% dan 97,5% dari distribusinya (Hyndman, 2014).

## 2.7 ARIMAX-Quantile Regression (ARIMAX-QR)

Model ARIMAX-Quantile Regression yang digunakan pada penelitian ini antara lain.

a. Model 1

ARIMAX-QR model 1 mengikuti metode yang di-usung oleh Arunraj dan Ahrens (2015). Metode ini menggunakan nilai ramalan menggunakan metode ARIMA dari data serta variabel-variabel eksogen lainnya (variabel *dummy*) sebagai prediktor untuk regresi kuantil. Persamaan dari model ini adalah sebagai berikut.

$$\hat{Y}_t(\tau) = Q_\tau(Y_t | \hat{Z}_t, t, D_{2,t}, \dots, tD_{3,t}, M_{1,t}, \dots, M_{12,t}, V_{1,t}, \dots, V_{4,t+1}), \quad (2.39)$$

dengan  $\hat{Z}_t$  merupakan nilai ramalan  $Y_t$  menggunakan metode ARIMA dan  $t, D_{2,t}, \dots, tD_{3,t}, M_{1,t}, \dots, M_{12,t}, V_{1,t}, \dots, V_{4,t+1}$  variabel ekso-gen yang diduga mempengaruhi (variabel *dummy*).

b. Model 2

Pada pemodelan ARIMAX-QR ini menggunakan nilai prediksi metode ARIMAX dari data sebagai variabel prediktor pada regresi kuantil. Model ini dapat ditulis sebagai berikut.

$$\hat{Y}_t(\tau) = Q_\tau(Y_t | \hat{Z}_t^*), \quad (2.40)$$

dengan  $\hat{Z}_t^*$  merupakan nilai ramalan  $Y_t$  menggunakan metode ARIMAX.

c. Model 3

Jenis ARIMAX-QR yang ketiga adalah memodelkan residual dari *time series regression* menggunakan regresi kuantil dengan variabel prediktor meliputi nilai ramalan menggunakan metode ARIMA dari data serta lag-lag dari residual tersebut yang telah stasioner. Model ini dapat ditulis sebagai berikut.

$$\begin{aligned} \hat{Y}_t(\tau) = & \beta_1 t + \beta_2 D_{1,t} + \dots + \beta_5 t D_{2,t} + \gamma_1 M_{1,t} + \dots + \gamma_{12} M_{12,t} + \delta_1 V_{1,t} + \dots + \\ & \delta_4 V_{4,t} + \dots + \alpha_4 V_{4,t+1} + Q_\tau(a_t | \hat{Z}_t, a_{t-1}, a_{t-2}, \dots). \end{aligned} \quad (2.41)$$

d. Model 4

Tahap pertama yang dilakukan pada pemodelan menggunakan metode ARIMAX-QR model 4 adalah melakukan *time series regression* terlebih dahulu, yang kemudian akan menghasilkan nilai prediksi untuk data *in-sample* dan *out-sample* ( $\hat{Y}_t^{(1)}$ ). Pada tahap kedua dilakukan pemodelan menggunakan regresi kuantil antara data ( $Y_t$ ) dengan variabel prediktor meliputi nilai prediksi *time series regression* ( $\hat{Y}_t^{(1)}$ ) dan lag-lag dari  $Y_t$  yang diidentifikasi menggunakan plot PACF dari residual yang sudah stasioner. Model ini dapat dituliskan sebagai berikut.

$$\hat{Y}_t(\tau) = Q_\tau(Y_t | \hat{Y}_t^{(1)}, Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}). \quad (2.42)$$

## 2.8 Evaluasi Model

Salah satu tujuan melakukan peramalan adalah meningkatkan akurasi hasil ramalan. Evaluasi model pada penelitian ini akan menggunakan kriteria kebaikan model berdasarkan median yaitu *Median Absolute Error* (MdAE) dengan rumus sebagai berikut.

$$\text{MdAE} = \text{median}(|e_l|), \quad (2.43)$$

dengan  $e_l = Y_{n+l} - \hat{Y}_n(l)$  (Hyndman & Koehler, 2006).

*Cross-validation* merupakan salah satu cara mengukur kinerja peramalan model. Cara biasa untuk melakukan *cross-validation* model adalah dengan mengujinya pada sekumpulan data yang tidak digunakan dalam *fitting* (*out-sample*). Dalam peramalan data *time series*, *cross-validation* dilakukan dengan cara sebagai berikut (Hyndman, 2010).

1. Membuat model dari data  $Y_1, Y_2, \dots, Y_n$  dan menghitung nilai ramalan satu observasi kedepan  $\hat{Y}_{n+1}$ . Kemudian menghitung kesalahan ramalannya ( $e_{n+1}^* = Y_{n+1} - \hat{Y}_n(1)$ ).

2. Mengulangi langkah 1 untuk  $t = n, n + 1, \dots, M - 1$  dengan  $n$  adalah jumlah data *in-sample*.
3. Menghitung nilai akurasi dari  $e_{n+1}^*, e_{n+2}^*, \dots, e_M^*$ .

*(halaman ini sengaja dikosongkan)*

## BAB III

### METODOLOGI PENELITIAN

#### 3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder mengenai *inflow* dan *outflow* uang kertas per pecahan mulai dari pecahan Rp1.000,000 hingga Rp100.000,00 di Jawa Timur yang diperoleh dari Departemen Pengelolaan Uang, Kantor Pusat Bank Indonesia. Periode waktu yang digunakan adalah Januari 2003 hingga Desember 2016.

#### 3.2 Variabel Penelitian

Tugas Akhir ini menggunakan variabel *inflow* dan *outflow* uang kertas per pecahan dengan periode bulanan dan beberapa variabel *dummy* sebagai input pada *time series regression* dengan penjelasan sebagai berikut.

**Tabel 3. 1** Variabel Penelitian

<b>Data</b>	<b>Variabel</b>	<b>Pecahan Uang Kartal</b>
<i>Outflow</i>	$Y_{1,t}$	Rp100.000,00 pada bulan ke- $t$
	$Y_{2,t}$	Rp50.000,00 pada bulan ke- $t$
	$Y_{3,t}$	Rp20.000,00 pada bulan ke- $t$
	$Y_{4,t}$	Rp10.000,00 pada bulan ke- $t$
	$Y_{5,t}$	Rp5.000,00 pada bulan ke- $t$
	$Y_{6,t}$	Rp2.000,00 pada bulan ke- $t$
	$Y_{7,t}$	Rp1.000,00 pada bulan ke- $t$

**Tabel 3.1** Variabel Penelitian (lanjutan)

<b>Data</b>	<b>Variabel</b>	<b>Pecahan Uang Kartal</b>
<i>Inflow</i>	$Y_{8,t}$	Rp100.000,00 pada bulan ke- $t$
	$Y_{9,t}$	Rp50.000,00 pada bulan ke- $t$
	$Y_{10,t}$	Rp20.000,00 pada bulan ke- $t$
	$Y_{11,t}$	Rp10.000,00 pada bulan ke- $t$
	$Y_{12,t}$	Rp5.000,00 pada bulan ke- $t$
	$Y_{13,t}$	Rp2.000,00 pada bulan ke- $t$
	$Y_{14,t}$	Rp1.000,00 pada bulan ke- $t$

Selain variabel *inflow* dan *outflow*, akan digunakan pula variabel *dummy* yaitu *dummy* tren,

$t, D_{1,t}, D_{2,t}, tD_{1,t}, tD_{2,t}$  : pola *trend*

*dummy* musiman berikut,

$M_{1,t}, M_{2,t}, \dots, M_{12,t}$  : Bulan Januari, Februari, ... , Desember

dan *dummy* variasi kalender berikut,

$V_{1,t}, V_{2,t}, V_{3,t}, V_{4,t}$  : minggu ke-1 hingga minggu ke-4 pada bulan terjadinya Idul Fitri,

$V_{1,t-1}, V_{2,t-1}, V_{3,t-1}, V_{4,t-1}$  : minggu ke-1 hingga minggu ke-4 pada satu bulan sebelum Idul Fitri, dan

$V_{1,t+1}, V_{2,t+1}, V_{3,t+1}, V_{4,t+1}$  : minggu ke-1 hingga minggu ke-4 pada satu bulan setelah Idul Fitri,

dengan ketentuan minggu pada tiap bulannya adalah sebagai berikut,

minggu ke-1 : tanggal 1 hingga tanggal 7,

minggu ke-2 : tanggal 8 hingga tanggal 15,

minggu ke-3 : tanggal 16 hingga tanggal 23, dan



minggu ke-4 : tanggal 24 hingga tanggal terakhir di bulan yang bersangkutan.

Pola variasi kalender pada data mengikuti terjadinya Hari Raya Idul Fitri. Berikut disajikan data waktu terjadinya Hari Raya Idul Fitri dari tahun 2001 hingga 2016.

**Tabel 3. 2** Daftar Hari Raya Idul Fitri tahun 2001-2016

Tahun	Tanggal terjadinya Hari Raya Idul Fitri	Minggu ke- ( <i>j</i> )	Variabel <i>Dummy</i>		
			$V_{j,t-1}$	$V_{j,t}$	$V_{j,t+1}$
2001	16-17 Desember	3	November	Desember	Januari
2002	05-06 Desember	1	November	Desember	Januari
2003	25-26 November	4	Oktober	November	Desember
2004	13-14 November	2	Oktober	November	Desember
2005	03-04 November	1	Oktober	November	Desember
2006	23-24 Oktober	4	September	Oktober	November
2007	12-13 Oktober	2	September	Oktober	November
2008	01-02 Oktober	1	September	Oktober	November
2009	21-22 September	3	Agustus	September	Oktober
2010	10-11 September	2	Agustus	September	Oktober
2011	30-31 Agustus	4	Juli	Agustus	September
2012	19-20 Agustus	3	Juli	Agustus	September
2013	08-09 Agustus	2	Juli	Agustus	September
2014	28-29 Juli	4	Juni	Juli	Agustus
2015	17-18 Juli	3	Juni	Juli	Agustus
2016	6-7 Juli	1	Juni	Juli	Agustus

dengan,

$$V_{j,t} = \begin{cases} 1, & \text{bulan terjadinya Idul Fitri minggu ke-} j \\ 0, & \text{lainnya} \end{cases},$$

$$V_{j,t-1} = \begin{cases} 1, & \text{satu bulan sebelum terjadinya Idul Fitri minggu ke-} j \\ 0, & \text{lainnya} \end{cases},$$

$$V_{j,t+1} = \begin{cases} 1, & \text{satu bulan setelah terjadinya Idul Fitri minggu ke-} j \\ 0, & \text{lainnya} \end{cases},$$

dan  $j = 1, 2, 3, 4$ .

### 3.3 Langkah Penelitian

Dalam penelitian ini akan dilakukan dua macam analisis, yakni yang pertama adalah menggunakan studi simulasi, dan yang kedua adalah analisis pada data *inflow* dan *outflow*.

#### 3.3.1 Studi Simulasi

Studi simulasi dilakukan dengan tujuan supaya lebih memahami data yang mengandung pola tren, musiman dan variasi kalender maka dilakukan studi simulasi mengenai data dengan periode mulai Januari 2001 hingga Desember 2016. Beberapa langkah penelitian pada studi simulasi adalah sebagai berikut.

1. Data simulasi yang digunakan merupakan data yang mengandung pola tren, musiman, variasi kalender dan *error*. Bentuk umum model peramalan untuk data yang mengandung pola tren, musiman dan variasi kalender adalah,

$$Y_t = T_t + S_t + V_t + n_t$$

dengan,

$T_t$  : suatu tren, misal tren linier dalam bentuk  $T_t = a + b t$ ,

$S_t$  : pola musiman (*seasonal*), dapat berbentuk *dummy* maupun sinus,

$V_t$  : variasi kalender,

$n_t$  : suatu deret *noise* yang bisa random atau bisa mengandung autokorelasi, dapat mengikuti pola linier maupun nonlinier.

Terdapat dua skenario data yang akan digunakan, yang pertama adalah data dengan pola musiman homogen dengan *error* linier dan yang kedua adalah data dengan pola musiman non-homogen dengan *error* linier. Persamaan yang digunakan untuk membangkitkan data pada tiap pola di masing-masing skenario disajikan pada Bab 4.

1. Menentukan variabel *dummy* untuk memodelkan pola data pada langkah 1, antara lain:

- a. Tren

Data diasumsikan mengandung pola tren linier, sehingga *dummy* yang digunakan adalah

$$t = 1, 2, \dots, n$$

- b. Musiman

Data diasumsikan memiliki pola musiman bulanan, sehingga variabel *dummy* yang digunakan dengan tujuan merekonstruksi pola musiman adalah,

$$M_{i,t} = \begin{cases} 1, & \text{untuk bulan ke-} i \\ 0, & \text{untuk bulan yang lain} \end{cases} \quad \text{dengan } i = \begin{cases} 1, \text{Januari} \\ 2, \text{Februari} \\ \vdots \\ 12, \text{Desember.} \end{cases}$$

- c. Variasi Kalender

Diasumsikan efek Hari Raya Idul Fitri berkaitan dengan minggu terjadinya Hari Raya Idul Fitri, baik di satu bulan sebelum Idul Fitri ( $t-1$ ) dan bulan saat terjadinya Idul Fitri ( $t$ )

2. Membagi data *in-sample* dan *out-sample* yang akan digunakan dalam analisis yaitu data Januari 2001 hingga Desember 2015 sebagai data *in-sample* dan Januari 2016 hingga Desember 2016 sebagai data *out-sample*.
3. Melakukan pemodelan ramalan pada data simulasi menggunakan metode ARIMAX dan model *hybrid* ARIMAX-*Quantile Regression* (tahapan dari masing-masing metode akan dijelaskan pada subbab 3.3.2).
4. Membandingkan akurasi ramalan tiap metode peramalan pada masing-masing skenario menggunakan kriteria RMSE, MAE dan MdAE.
5. Menarik kesimpulan.

### 3.3.2 Peramalan *Inflow* dan *Outflow* Jawa Timur

Dalam melakukan analisis pada penelitian ini menggunakan data *inflow* dan *outflow*, langkah analisis yang dilakukan adalah sebagai berikut.

1. Mendeskripsikan karakteristik data *inflow* dan *outflow* uang kertas per pecahan di Jawa Timur.
2. Mengidentifikasi pola data menggunakan *time series plot* dan diagram batang. Diasumsikan data mengandung pola tren, musiman, variasi kalender dan *error* yang diduga belum random.
3. Menentukan variabel *dummy* untuk memodelkan pola data pada langkah 2, antara lain:

a. Tren

Data diasumsikan mengandung pola tren linier, sehingga *dummy* yang digunakan adalah  $t = 1, 2, \dots, n$ .

b. Musiman

Data diasumsikan memiliki pola musiman bulanan, sehingga variabel *dummy* yang digunakan dengan tujuan merekonstruksi pola musiman adalah,

$$M_{i,t} = \begin{cases} 1, \text{ bulan ke-}i \\ 0, \text{ bulan yang lain} \end{cases} \quad \text{dengan } i = \begin{cases} 1, \text{ Januari} \\ 2, \text{ Februari} \\ \vdots \\ 12, \text{ Desember.} \end{cases}$$

c. Variasi Kalender

Diasumsikan efek Hari Raya Idul Fitri berkaitan dengan minggu terjadinya Hari Raya Idul Fitri, baik di satu bulan sebelum Idul Fitri ( $t - 1$ ), bulan saat terjadinya Idul Fitri ( $t$ ) dan satu bulan setelah Idul Fitri ( $t+1$ ), sehingga variabel *dummy* yang digunakan adalah,

- Efek satu bulan sebelum Hari Raya Idul Fitri ( $t - 1$ )  

$$V_{j,t-1} = \begin{cases} 1, & \text{satu bulan sebelum Hari Idul Fitri minggu ke-}j \\ 0, & \text{lainnya} \end{cases}$$
- Efek bulan saat terjadinya Hari Raya Idul Fitri ( $t$ )  

$$V_{j,t} = \begin{cases} 1, & \text{bulan terjadinya Idul Fitri minggu ke-}j \\ 0, & \text{lainnya} \end{cases}$$
- Efek satu bulan setelah Hari Raya Idul Fitri ( $t+1$ )  

$$V_{j,t+1} = \begin{cases} 1, & \text{satu bulan setelah Hari Idul Fitri minggu ke-}j \\ 0, & \text{lainnya} \end{cases}$$

dengan  $j = 1, 2, 3, 4$ .

4. Membagi data menjadi data *in-sample* dan data *out-sample*. Data pada periode Januari 2003 hingga Desember 2015 menjadi data *in-sample* dan data periode Januari 2016 hingga Desember 2016 menjadi data *out-sample*.
5. Melakukan pemodelan ramalan menggunakan metode *Time Series Regression* dengan efek variasi kalender pada data *inflow* dan *outflow* dengan tahapan sebagai berikut.
  - i. Meregresikan variabel respon dengan variabel prediktor yang berupa *dummy* pola tren, *dummy* musiman dan *dummy* variasi kalender,
  - ii. Melakukan cek diagnosa residual model meliputi meliputi uji *white noise* residual menggunakan uji Ljung-Box, apabila tidak memenuhi asumsi *white noise* maka lag  $Y_t$  digunakan sebagai tambahan variabel prediktor. Pemilihan lag dapat ditentukan berdasarkan plot ACF dan PACF residual, Selain itu dilakukan pula pengujian distribusi normal menggunakan uji Kolmogorov-Smirnov,
  - iii. Melakukan estimasi parameter,
  - iv. Melakukan uji signifikansi parameter,

6. Memodelkan data *inflow* dan *outflow* menggunakan metode ARIMAX (ARIMA dengan efek variasi kalender) dengan tahapan sebagai berikut.
  - i. Meregresikan variabel respon dengan variabel prediktor yang berupa *dummy* pola tren, *dummy* musiman dan *dummy* variasi kalender,
  - ii. Menduga orde  $p$  dan  $q$  dari plot ACF dan PACF residual,
  - iii. Melakukan cek diagnosa pada residual, jika belum *white noise* maka lag yang signifikan berdasarkan uji Ljung-Box ditambahkan sebagai variabel independen,
  - iv. Melakukan estimasi parameter
  - v. Melakukan cek diagnosa kembali, apabila asumsi residual belum terpenuhi maka dilakukan hal yang sama seperti langkah iii,
  - vi. Melakukan peramalan dengan metode ARIMAX (ARIMA dengan variasi kalender),
  - vii. Mengitung nilai RMSE, MAE, dan MdAE untuk hasil ramalan data *out-sample*.
7. Melakukan pemodelan ARIMAX-*Quantile Regression*.
  - a. Model 1 yaitu melakukan pemodelan dengan memasukkan hasil ramalan menggunakan model ARIMA pada regresi kuantil (Arunraj & Ahrens, 2015), dengan tahapan berikut:
    - i. Melakukan peramalan berdasarkan model ARIMA terbaik untuk data *in-sample* ( $\hat{Z}_t$ ),
    - ii. Melakukan pemodelan menggunakan *Quantile Regression* antara variabel prediktor *in-sample* dan variabel prediktor (*dummy*) serta nilai ramalan ARIMA data *in-sample* pada langkah 7a(i) ( $\hat{Z}_t$ ), dimana yang menjadi responnya adalah  $Y_t$  dengan


- prediktor meliputi variabel  $\hat{Z}_t$  serta variabel *dummy* tren, musiman dan variasi kalender,
- iii. Menghitung nilai RMSE, MAE, dan MdAE untuk hasil ramalan model gabungan metode QR pada data *out-sample*.
- b. Model 2 yaitu memodelkan data menggunakan regresi kuantil dengan prediktornya meliputi hasil prediksi ARIMAX dari data, dengan tahapan sebagai berikut.
- i. Melakukan peramalan berdasarkan model ARIMAX terbaik untuk data *in-sample* dan *out-sample* ( $\hat{Z}_t^*$ ) seperti pada langkah 6,
  - ii. Memodelkan data ( $Y_t$ ) dengan prediktor nilai prediksi ARIMAX ( $\hat{Z}_t^*$ ) menggunakan regresi kuantil,
  - iii. Menghitung nilai RMSE, MAE, dan MdAE untuk hasil ramalan model gabungan metode QR pada data *out-sample*.
- c. Model 3 yaitu melakukan pemodelan pada residual (hasil dekomposisi) menggunakan regresi kuantil
- iv. Melakukan peramalan berdasarkan model ARIMA terbaik untuk data *in-sample* dan *out-sample* ( $\hat{Z}_t$ ),
  - v. Melakukan pemodelan regresi *time series* seperti pada langkah 5(i),
  - vi. Mengecek pola pada plot ACF dan PACF dari residual pada tahap (ii) untuk mendeteksi lag  $n_t$  yang kemudian dijadikan variabel prediktor bersama dengan nilai prediksi ARIMA pada regresi kuantil,
  - vii. Memodelkan residual TSR ( $n_t$ ) pada tahap 7b(ii) dengan lagnya serta nilai prediksi ARIMA data *in-sample* pada tahap (i) sebagai variabel prediktor

- menggunakan metode *Quantile Regression* untuk kuantil 0,025; 0,5 dan 0,975,
- viii. Melakukan peramalan menggunakan ARIMAX-*Quantile Regression* dengan menggabungkan nilai prediksi TSR ( $\hat{Y}_t^{(1)}$ ) pada tahap 7b(ii) dengan nilai prediksi regresi kuantil residual pada tahap 7b(iv),
  - ix. Menghitung nilai RMSE, MAE, dan MdAE untuk hasil ramalan model gabungan metode QR pada data *out-sample*.
- d. Model 4, melakukan pemodelan regresi kuantil pada data dengan prediktor meliputi nilai prediksi model *time series regression* dan lag  $Y_t$ .
- i. Melakukan pemodelan regresi *time series* seperti pada langkah 5(i),
  - ii. Mengecek pola pada plot ACF dan PACF dari residual pada tahap (i) untuk medeteksi lag  $Y_t$ ,
  - iii. Melakukan pemodelan menggunakan regresi kuantil dengan variabel prediktor meliputi lag  $Y_t$  dan nilai prediksi TSR ( $\hat{Y}_t^{(1)}$ ) dengan respon  $Y_t$ , untuk kuantil 0,025; 0,5 dan 0,975,
  - iv. Menghitung nilai RMSE, MAE, dan MdAE untuk hasil ramalan model gabungan metode QR pada data *out-sample*.
8. Melakukan perbandingan kebaikan model ARIMAX-QR dengan model individu lainnya untuk memilih model terbaik.
9. Melakukan peramalan titik dan interval berdasarkan model terbaik pada tiap pecahan.
10. Menarik kesimpulan dan saran.




### 3.3.3 Diagram Alir

Berdasarkan langkah analisis diatas, diagram alir pada penelitian ini adalah sebagai berikut.




**Gambar 3.1** Diagram Alir Penelitian

Diagram Alir Pembentukan Model ARIMAX-QR berdasarkan Arunraj & Ahrens (2015) adalah sebagai berikut.




**Gambar 3.2** Diagram Alir Penelitian ARIMAX-QR Model 1 (Arunraj & Ahrens, 2015)

Diagram Alir Pembentukan Model ARIMAX-QR Model 2 adalah sebagai berikut.




**Gambar 3.3** Diagram Alir Penelitian ARIMAX-QR Model 2

Diagram Alir Pembentukan Model ARIMAX-QR Model 3 adalah sebagai berikut.



**Gambar 3.4** Diagram Alir Penelitian ARIMAX-QR Model 3

Diagram Alir Pembentukan Model ARIMAX-QR Model 4 adalah sebagai berikut.



**Gambar 3.5** Diagram Alir Penelitian ARIMAX-QR Model 4

*(halaman ini sengaja dikosongkan)*

## BAB IV

### ANALISIS DAN PEMBAHASAN

Pada bab ini akan dibahas hasil analisis dan pembahasan mengenai peramalan *inflow* dan *outflow* uang kartal per pecahan Bank Indonesia di Jawa Timur. Peramalan dilakukan dengan menggunakan metode *time series regression*, ARIMAX, dan metode *hybrid ARIMAX-Quantile Regression*. Metode terbaik dipilih berdasarkan kriteria *out-sample* yang dihasilkan pada peramalan *inflow* dan *outflow* untuk 12 bulan ke depan. Untuk lebih memahami mengenai penggunaan metode yang digunakan, dilakukan studi simulasi mengenai data yang diasumsikan memiliki kesamaan dengan data *inflow* dan *outflow* uang kartal.

#### 4.1 Studi Simulasi

Data *inflow* dan *outflow* diduga mengandung suatu pola tren, musiman serta dipengaruhi variasi kalender tertentu. Untuk lebih memahami data yang mengandung pola tren, musiman dan variasi kalender maka dilakukan studi simulasi mengenai data dengan periode mulai Januari 2001 hingga Desember 2016. Bentuk umum model peramalan untuk data yang mengandung pola tren, musiman dan variasi kalender adalah sebagai berikut.

$$Y_t = T_t + S_t + V_t + n_t .$$

Terdapat dua skenario simulasi data yang akan digunakan dalam studi ini yaitu data yang mengandung pola tren, musiman dan variasi kalender dengan varians yang homogen dan tidak homogen. Pola yang memiliki persamaan yang sama untuk tiap skenario adalah pola tren, variasi kalender serta deret *noise*. Persamaan matematis untuk pola yang tetap ini adalah sebagai berikut.

a. Pola Tren ( $T_t$ )

Model :  $T_t = 0,15 t$  ,  $t = 1, 2, \dots, 192$


b. Pola Variasi Kalender ( $V_t$ )

Model :

$$V_t = 8V_{1,t} + 16V_{2,t} + 26V_{3,t} + 34V_{4,t} + 29V_{1,t-1} + 21V_{2,t-1} + 11V_{3,t-1} + 8V_{4,t-1}$$

c. Deret noise ( $n_t$ )Model :  $n_t = 0,7n_{t-1} + u_t$  dengan  $u_t \sim N(0;1^2)$ .

Dari masing-masing persamaan diatas, maka jangkauan dari masing-masing pola data disajikan pada Gambar 4.1.



**Gambar 4.1** Jangkauan data Simulasi untuk pola Tetap



Pola variasi kalender pada data mengikuti terjadinya Hari Raya Idul Fitri. Data waktu terjadinya Hari Raya Idul Fitri dari tahun 2001 hingga 2016 disajikan pada Tabel 3.2.

#### 4.1.1 Studi Simulasi Skenario 1 (Varians Musiman Homogen)

Data simulasi dibangun dengan menambahkan data berpola tren, musiman, dan variasi kalender serta error linier. Pola Musiman (*Seasonal*) yang digunakan pada skenario ini dapat ditulis sebagai berikut.


Model :

$$S_{1,t} = 21M_{1,t} + 23M_{2,t} + 25M_{3,t} + 24M_{4,t} + 22M_{5,t} + 20M_{6,t} + 18M_{7,t} + 16M_{8,t} + 15M_{9,t} + 16M_{10,t} + 17M_{11,t} + 20M_{12,t}$$

Sehingga persamaan umum untuk data yang mengandung pola trend, musiman dan variasi kalender serta *noise* pada skenario 1 dapat dituliskan sebagai berikut.

$$Y_t = T_t + S_{1,t} + V_t + n_t$$


Dilakukan replikasi sebanyak lima kali dengan membangkitkan kembali  $u_t \sim N(0,1^2)$  dan membuat data error linier yang mengikuti model AR(1). Jangkauan dari pola musiman dengan varians homogen yang digunakan dapat divisualisasikan sebagai berikut.



**Gambar 4.2** Plot Jangkauan Pola Musiman Data Simulasi Skenario 1

Dari Gambar 4.2, terlihat bahwa pola tren dan variasi kalender cukup mendominasi dibandingkan pola musiman dan error linier. Sehingga apabila data yang mewakili masing-masing pola ini digabungkan akan menjadi data yang mengandung pola tren, musiman, variasi kalender dan error linier. Ilustrasi grafik

yang dihasilkan dari simulasi disajikan dalam plot *Time Series* dan *boxplot* yang ditunjukkan pada Gambar 4.3.



**Gambar 4.3** Plot *Time Series* Data (a), dan *Boxplot* dari Data yaitu yang dikategorikan Tiap Bulan (b) serta Setelah Dihilangan Pola Tren dan Variasi Kalender (c), dari Data Simulasi Skenario 1


Dengan menggunakan data simulasi ini, kemudian dilakukanlah peramalan menggunakan ARIMAX, dan *hybrid ARIMAX-Quantile Regression*. Dari Gambar 4.3(b) bahwa apabila dilihat berdasarkan bulan, maka variasi dari data pada tiap-tiap bulan nampak heterogen, terutama pada bulan Juli hingga Oktober, dimana pada bulan-bulan ini variansnya lebih besar dibanding bulan-bulan lainnya. Namun ternyata, setelah dihilangkan efek pola tren dan variasi kalendernya seperti pada gambar (c), varians dari tiap-tiap bulan cenderung homogen. Perbedaan antara gambar (b) dan (c) menunjukkan bagaimana pengaruh dari adanya variasi kalender. Pada Gambar 4.2 diperlihatkan bahwa data yang mengandung pola tren, musiman dan variasi kalender apabila dimodelkan dengan model tren dan

musiman saja (gambar (b)) akan memberikan hasil yang tidak akurat, khususnya pada bulan yang mengandung efek variasi kalender. Oleh sebab itulah, pada analisis selanjutnya akan digunakan variabel *dummy* untuk variasi kalender supaya mampu mengikuti pola variasi kalender.

Berdasarkan pembentukan variabel yang telah dilakukan, maka model regresi *time series* yang menggambarkan hubungan data simulasi pada replikasi 1 dengan efek pola tren, musiman dan variasi kalender adalah mengikuti persamaan berikut.

$$\begin{aligned}
 Y_{1,t} = & 0,153t + 21,054M_{1,t} + 22,961M_{2,t} + 24,931M_{3,t} + 24,256M_{4,t} + \\
 & 21,763M_{5,t} + 19,729M_{6,t} + 17,370M_{7,t} + 15,653M_{8,t} + 14,951M_{9,t} + \\
 & 16,146M_{10,t} + 17,325M_{11,t} + 20,516M_{12,t} + 7,491V_{1,t} + 15,113V_{2,t} + \\
 & 26,457V_{3,t} + 34,634V_{4,t} + 29,442V_{1,t-1} + 21,155V_{2,t-1} + 11,281V_{3,t-1} + \\
 & 9,359V_{4,t-1} + n_t
 \end{aligned}$$

Selain menguji signifikansi parameter model regresi *Time Series*, dilakukan pengujian asumsi *white noise* dan distribusi normal dari residual model regresi *time series*.



**Gambar 4.4** Plot ACF dan PACF Residual Model TSR Skenario 1 Replikasi 1

Berdasarkan Gambar 4.4, nampak bahwa residual yang dihasilkan *Time Series regression* (TSR) data simulasi belum memenuhi asumsi *white noise*. Hal ini ditunjukkan dengan masih adanya ACF dan PACF yang keluar batas, atau dapat dikatakan bahwa residual masih mengandung suatu model tertentu. Selain menggunakan plot ACF dan PACF, dilakukan pengujian

independensi residual menggunakan uji Ljung-Box dan diperoleh hasil sebagai berikut.

**Tabel 4.1** Uji Ljung-Box Residual Model TSR Skenario 1 Replikasi 1

Lag	Chi-Squared	P-Value
6	110,0506	0,0000
12	114,1330	0,0000
18	141,2461	0,0000
24	144,8113	0,0000
36	172,0173	0,0000
48	185,5573	0,0000

Residual yang dihasilkan dari pemodelan TSR masih belum memenuhi asumsi independensi antar residual. Hal ini ditunjukkan oleh *p-value* yang bernilai kurang dari 0,05 pada lag-lag yang digunakan, seperti yang dapat dilihat pada Tabel 4.1.

Tahapan selanjutnya adalah melakukan pengujian asumsi distribusi normal untuk residual model TSR pada tiap replikasi. Pengujian normalitas untuk residual TSR pada replikasi 1-10.

**Tabel 4.2** Uji Asumsi Distribusi Normal Residual Model TSR Data Simulasi Skenario 1

Replikasi	Kolmogorov-Smirnov	P-Value
1	0,038	>0,150
2	0,042	>0,150
3	0,049	>0,150
4	0,055	>0,150
5	0,038	>0,150
6	0,051	>0,150
7	0,050	>0,150
8	0,050	>0,150
9	0,043	>0,150
10	0,061	0,103

Pada hasil pengujian asumsi distribusi normal dari residual model TSR data pada replikasi 1 menghasilkan *p-value* kurang dari 0,010 atau bernilai kurang dari alfa (0,05) yang berarti residual model TSR pada replikasi 1 tidak memenuhi asumsi distribusi normal seperti yang ditunjukkan pada Tabel 4.2. Hal yang beda ditunjukkan oleh replikasi 1 hingga 10, yaitu *p-value* bernilai lebih dari 0,05 maka Gagal Tolak  $H_0$  yang berarti residual model TSR

pada replikasi 1 hingga replikasi 10 memenuhi asumsi distribusi normal.

Dengan cara yang sama, dilakukan pemodelan menggunakan regresi *Time Series* pada data replikasi 2 hingga 10. Dari hasil yang diperoleh maka dapat diketahui bahwa residual model TSR pada replikasi 1 hingga replikasi 10 masih belum memenuhi asumsi *white noise*. Hal ini juga ditunjukkan oleh plot ACF dan PACF replikasi 2 hingga replikasi 10 yang masih terdapat ACF dan PACF yang keluar batas signifikansi. Oleh karena itu selanjutnya dilakukan pemodelan terhadap residual. Berdasarkan plot ACF dan PACF yang dihasilkan maka residual pada tiap-tiap replikasi dimodelkan dengan suatu model ARIMA tertentu yang disajikan pada Tabel 4.3 berikut.

**Tabel 4.3** Estimasi dan Signifikansi Parameter Model ARIMA Residual TSR Simulasi Skenario 1

Replikasi	Model ARIMA	Koefisien Model	Std. Error	P-Value
1	ARIMA(1,0,0)	$\phi_1 = 0,6172$	0,0585	0,0000
2	ARIMA(1,0,0)	$\phi_1 = 0,6750$	0,0552	0,0000
3	ARIMA(1,0,0)	$\phi_1 = 0,7654$	0,0485	0,0000
4	ARIMA(1,0,0)	$\phi_1 = 0,7217$	0,0518	0,0000
5	ARIMA(1,0,0)	$\phi_1 = 0,6935$	0,0540	0,0000
6	ARIMA(1,0,0)	$\phi_1 = 0,6077$	0,0594	0,0000
7	ARIMA(1,0,0)	$\phi_1 = 0,7003$	0,0525	0,0000
8	ARIMA(1,0,0)	$\phi_1 = 0,6367$	0,0573	0,0000
9	ARIMA(1,0,0)	$\phi_1 = 0,6478$	0,0567	0,0000
10	ARIMA(1,0,0)	$\phi_1 = 0,5865$	0,0616	0,0000

Pada Tabel 4.3, koefisien pada tiap model ARIMA di tiap replikasi menghasilkan p-value kurang dari 0,05 yang berarti Tolak  $H_0$  atau koefisien parameternya signifikan. Selanjutnya adalah melakukan pengujian asumsi *white noise* dan distribusi normal dari residual model ARIMA yang dihasilkan yang disajikan pada Tabel 4.4 berikut.

**Tabel 4.4** Pemenuhan Asumsi Model ARIMA Residual TSR Simulasi Skenario 1

Replikasi	Model ARIMA	Pemenuhan Asumsi Residual Model ARIMA	
		White Noise	Distribusi Normal
1	ARIMA(1,0,0)	✓	✓
2	ARIMA(1,0,0)	✓	✓
3	ARIMA(1,0,0)	✓	✓
4	ARIMA(1,0,0)	✓	✓
5	ARIMA(1,0,0)	✓	✓
6	ARIMA(1,0,0)	✓	✓
7	ARIMA(1,0,0)	✓	✓
8	ARIMA(1,0,0)	✓	✓
9	ARIMA(1,0,0)	✓	✓
10	ARIMA(1,0,0)	✓	✓


Keterangan: V = Terpenuhi

Model ARIMAX pada data skenario 1 replikasi 1 dapat dituliskan sebagai berikut.

$$\begin{aligned}
 Y_{1,1,t} = & 0,153 t + 21,054 M_{1,t} + 22,961 M_{2,t} + 24,931 M_{3,t} + 24,256 M_{4,t} + \\
 & 21,763 M_{5,t} + 19,729 M_{6,t} + 17,370 M_{7,t} + 15,653 M_{8,t} + 14,951 M_{9,t} + \\
 & 16,146 M_{10,t} + 17,325 M_{11,t} + 20,516 M_{12,t} + 7,491 V_{1,t} + 15,113 V_{2,t} + \\
 & 26,457 V_{3,t} + 34,634 V_{4,t} + 29,442 V_{1,t-1} + 21,155 V_{2,t-1} + 11,281 V_{3,t-1} + \\
 & 9,359 V_{4,t-1} + \frac{1}{(1-0,617B)} a_t
 \end{aligned}$$


Metode selanjutnya yang digunakan adalah model *hybrid ARIMAX-Quantile Regression* yaitu menambahkan nilai ramalan model ARIMA data *in-sample* menjadi salah satu variabel prediktor pada *time Series regression* menggunakan *quantile regression*. Sebelum membentuk model ARIMA, tahapan pertama

yang dilakukan adalah identifikasi model yaitu menguji stasioner data. Berikut adalah plot ACF data simulasi skenario 2 replikasi 1.



**Gambar 4.5** Plot ACF Data Simulasi Skenario 1 Replikasi 1

Berdasarkan Gambar 4.5, ACF membentuk pola turun lambat. Hal ini menunjukkan bahwa data belum stasioner pada *mean*, sehingga perlu dilakukan *differencing* pada data. Plot ACF dan PACF setelah dilakukan *differencing* 1 adalah sebagai berikut.



**Gambar 4.6** Plot ACF dan PACF Data Simulasi Skenario 1 Replikasi 1 Setelah *Differencing*

Setelah *differencing* maka data sudah memenuhi asumsi stasioner dalam *mean* yang ditunjukkan pada Gambar 4.6 dimana plot ACF mempunyai pola turun cepat atau *cut off*. Dari plot ACF dan PACF yang diperoleh kemudian ditentukan model dugaan ARIMA yang akan digunakan. Dugaan model ARIMA untuk semua data pada skenario 1 ini disajikan pada Tabel 4.5 berikut.

**Tabel 4.5** Model ARIMA dan Pengujian Asumsi Data tiap Replikasi Skenario 1

Replikasi	Model ARIMA	Signifikansi Parameter	Uji <i>White Noise</i>	Uji Normalitas
1	$((13,23],1,1)(1,0,0)^{12}$	✓	✓	×
2	$((13,23],1,1)(1,0,0)^{12}$	✓	✓	×
3	$((23],1,1)(1,0,0)^{12}$	✓	✓	×
4	$((13,23],1,1)(1,0,0)^{12}$	✓	✓	×
5	$((23],1,1)(1,0,0)^{12}$	✓	✓	×
6	$((13,23],1,1)(1,0,0)^{12}$	✓	✓	×
7	$((13,23],1,1)(1,0,0)^{12}$	✓	✓	×
8	$((13,23],1,1)(1,0,0)^{12}$	✓	✓	×
9	$((13,23],1,1)(1,0,0)^{12}$	✓	✓	×
10	$((13,23],1,1)(1,0,0)^{12}$	✓	✓	×

Tabel 4.7 menunjukkan model ARIMA yang digunakan untuk memodelkan tiap data replikasi skenario 1, mulai replikasi 1 hingga replikasi 10. Pada tabel tersebut juga disajikan hasil pengujian signifikansi parameter dan pengujian asumsi residual dari model ARIMA. Hasil yang disajikan pada Tabel 4.7 menunjukkan bahwa model dugaan pada tiap replikasi telah memenuhi asumsi *white noise* namun tidak distribusi normal. Hal ini mungkin disebabkan oleh data-data yang nilainya tinggi yang diduga diakibatkan oleh variasi kalender. Setelah didapatkan model ARIMA yang sesuai untuk masing-masing data kemudian dilakukan peramalan untuk data *in-sample* yang kemudian akan menjadi salah satu variabel prediktor bersama variabel *dummy* untuk *time series regression* menggunakan regresi kuantil. Hasil regresi kuantil antara data simulasi skenario 1 replikasi 1 untuk kuantil 0,025, 0,50 dan 0,975 disajikan pada Tabel 4.6.




**Tabel 4.6** Estimasi Koefisien ARIMAX-QR Model 1 Data Skenario 1 Replikasi 1

$\tau$	0,025	0,5	0,975
$t$	0,151	0,148	0,132
$M_{1,t}$	19,155	20,372	19,625
$M_{2,t}$	20,792	22,249	21,340
$M_{3,t}$	21,853	24,026	24,352
$M_{4,t}$	20,203	23,102	22,509
$M_{5,t}$	19,005	21,806	21,164
$M_{6,t}$	18,109	19,544	20,106
$M_{7,t}$	16,185	17,178	16,268
$M_{8,t}$	13,074	15,232	15,759
$M_{9,t}$	12,372	15,001	14,023
$M_{10,t}$	14,644	15,552	14,847
$M_{11,t}$	14,013	16,631	15,948
$M_{12,t}$	17,411	19,320	19,678
$V_{1,t}$	8,693	8,720	7,337
$V_{2,t}$	15,262	15,433	13,165
$V_{3,t}$	27,387	25,461	23,847
$V_{4,t}$	32,316	32,375	34,441
$V_{1,t-1}$	29,731	28,864	25,929
$V_{2,t-1}$	19,906	20,153	17,686
$V_{3,t-1}$	12,651	11,643	10,279
$V_{4,t-1}$	7,769	7,154	7,283
$\hat{Z}_t$	0,023	0,026	0,134
	(0,256)	(0,385)	(0,000)
<b>Keterangan:</b> Semua nilai signifikansi parameter bernilai 0.0000, kecuali yang diberi tanda (...)			

Pada Tabel 4.6 ditunjukkan nilai estimasi untuk koefisien regresi kuantil pada kuantil 0,025, 0,5 dan 0,975 untuk semua variabel independen. Model yang terbentuk untuk kuantil 0,5 adalah sebagai berikut.

$$\begin{aligned}
 Y_{1,1,t}(0,5) = & 0,148 t + 21,372 M_{1,t} + 22,249 M_{2,t} + 24,026 M_{3,t} + 23,102 M_{4,t} + \\
 & 21,806 M_{5,t} + 19,544 M_{6,t} + 17,178 M_{7,t} + 15,232 M_{8,t} + 15,001 M_{9,t} + \\
 & 15,552 M_{10,t} + 16,631 M_{11,t} + 19,320 M_{12,t} + 8,720 V_{1,t} + 15,433 V_{2,t} + \\
 & 25,461 V_{3,t} + 32,375 V_{4,t} + 28,864 V_{1,t-1} + 20,153 V_{2,t-1} + 11,643 V_{3,t-1} + \\
 & 7,154 V_{4,t-1} + 0,026 \hat{Z}_{1,1,t} + \varepsilon_t
 \end{aligned}$$

Dari model inilah kemudian yang digunakan untuk meramalkan data *in-sample* dan *out-sample*.



**Gambar 4.7** Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 1

Pada Gambar 4.7 ditunjukkan bahwa hasil ramalan untuk data *training* dan data *testing* mampu mengikuti nilai aktual dari data. Berdasarkan *paper* rujukan yang ditulis oleh Arunraj dan Ahrens (2015), tidak ada pengujian asumsi yang perlu dilakukan namun langsung mengestimasi nilai kuantilnya. Langkah yang sama dilakukan ulang untuk data replikasi 2 hingga 5.

Selain menerapkan ARIMAX-QR model 1 yang masih melibatkan *dummy*, diterapkan pula ARIMAX-QR model 2 dengan menggunakan nilai prediksi metode ARIMAX dari  $Y_t$  dilambangkan dengan  $\hat{Z}_t^*$  sebagai prediktor dalam regresi kuantil. Hasil regresi kuantil yang diperoleh disajikan pada Tabel 4.7.


**Tabel 4.7** Estimasi Parameter ARIMAX-QR Model 2 Residual Data Replikasi 1 Skenario 1

Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$\hat{Z}_{1,1,t}^*$	0,949	0,000	1,002	0,000	1,053	0,000

Dari hasil yang diperoleh ini maka untuk  $\tau = 0,050$  model yang terbentuk adalah sebagai berikut.

$$Y_{1,1,t} = 1,002\hat{Z}_{1,1,t}^* + \varepsilon_t.$$

Dengan menggunakan model ini, kemudian dilakukan peramalan untuk data *in-sample* dan *out-sample*.



**Gambar 4.8** Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 2

Selanjutnya dilakukan pemodelan ARIMAX-QR yaitu dengan melakukan dekomposisi terlebih dahulu terhadap data, kemudian melakukan regresi kuantil pada residual model dekomposisi dengan variabel prediktornya meliputi lag-lag dari residual tersebut dan nilai prediksi ARIMA dari data. Berdasarkan

PACF model dekomposisi yang telah stasioner, didapatkan bahwa lag 1 signifikan, oleh karena itu lag 1 dari residual ( $a_{t-1}$ ) akan dijadikan variabel prediktor dalam regresi kuantil. Hasil regresi kuantil dari residual model dekomposisi disajikan pada Tabel 4.8.

**Tabel 4.8** Estimasi Parameter ARIMAX-QR Model 3 Residual Data Replikasi 1 Skenario 1


Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$a_{1,1,t-1}$	0,697	0,000	0,536	0,000	1,073	0,000
$\hat{Z}_{1,1,t}$	-0,051	0,000	0,000	0,971	0,052	0,000

Tabel 4.8 menunjukkan nilai estimasi untuk koefisien regresi kuantil pada kuantil 0,025, 0,50 dan 0,975 untuk variabel prediktor yang digunakan. Model yang dihasilkan dari kuantil 0,025 dan 0,975 digunakan untuk memprediksi interval atau batas atas dan batas atas dari data. Model yang terbentuk pada kuantil 0,50 adalah sebagai berikut.

$$\begin{aligned}
 Y_{1,1,t} = & 0,153 t + 21,054 M_{1,t} + 22,961 M_{2,t} + 24,931 M_{3,t} + 24,256 M_{4,t} + \\
 & 21,763 M_{5,t} + 19,729 M_{6,t} + 17,370 M_{7,t} + 15,653 M_{8,t} + 14,951 M_{9,t} + \\
 & 16,146 M_{10,t} + 17,325 M_{11,t} + 20,516 M_{12,t} + 7,491 V_{1,t} + 15,113 V_{2,t} + \\
 & 26,457 V_{3,t} + 34,634 V_{4,t} + 29,442 V_{1,t-1} + 21,155 V_{2,t-1} + 11,281 V_{3,t-1} + \\
 & 9,359 V_{4,t-1} + \hat{a}_{1,1,t}(\tau) + \varepsilon_t
 \end{aligned}$$

Untuk  $\tau = 0,50$ ,  $\hat{a}_{1,1,t}(\tau) = 0,536a_{1,1,t-1} + 0,000\hat{Z}_{1,1,t} + \varepsilon_t$ .

Model inilah kemudian yang digunakan untuk meramalkan data *out-sample*. Plot nilai prediksi untuk data *in-sample* dan data *out-sample* dari ARIMAX-QR model 3 disajikan pada Gambar 4.9. Dari gambar tersebut nampak bahwa semakin jauh periode ramalan yang dilakukan maka ramalan interval yang dihasilkan dari model ini akan semakin lebar.



**Gambar 4.9** Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 3

ARIMAX-QR jenis ke empat adalah melakukan regresi kuantil antara data ( $Y_t$ ) dengan prediktor yang meliputi nilai prediksi model TSR ( $\hat{Y}_t^{(1)}$ ) dan lag dari  $Y_t$ . Berdasarkan plot PACF residual, didapatkan bahwa lag 1 signifikan, sehingga lag 1 ( $Y_{t-1}$ ) dijadikan variabel prediktor pada model ini. Hasil regresi kuantil dari model ini disajikan pada Tabel 4.9.

**Tabel 4.9** Estimasi Parameter ARIMAX-QR Model 4 Residual Data Replikasi 1 Skenario 1

Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$\hat{Y}_{1,1,t}^{(1)}$	0,934	0,000	1,003	0,000	0,986	0,000
$Y_{1,1,t-1}$	0,003	0,871	-0,001	0,993	0,081	0,000


Model yang terbentuk untuk  $\tau = 0,50$  dapat dituliskan seperti berikut.

$$Y_{1,1,t} = 1,003 \hat{Y}_{1,1,t}^{(1)} - 0,001 Y_{1,1,t-1} + \varepsilon_t$$

dengan,

$$\begin{aligned} \hat{Y}_{1,1,t}^{(1)} = & 0,153 t + 21,054 M_{1,t} + 22,961 M_{2,t} + 24,931 M_{3,t} + 24,256 M_{4,t} + \\ & 21,763 M_{5,t} + 19,729 M_{6,t} + 17,370 M_{7,t} + 15,653 M_{8,t} + 14,951 M_{9,t} + \\ & 16,146 M_{10,t} + 17,325 M_{11,t} + 20,516 M_{12,t} + 7,491 V_{1,t} + 15,113 V_{2,t} + \\ & 26,457 V_{3,t} + 34,634 V_{4,t} + 29,442 V_{1,t-1} + 21,155 V_{2,t-1} + 11,281 V_{3,t-1} + \\ & 9,359 V_{4,t-1}. \end{aligned}$$

Model ini kemudian digunakan untuk meramalkan data *in-sample* dan *out-sample* dengan hasil sebagai berikut.



**Gambar 4.10** Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 4

Dari sepuluh replikasi yang telah dilakukan dan dianalisis menggunakan metode ARIMAX dan ARIMAX-QR model 1, model 2, model 3, dan model 4 maka kemudian dihitung nilai kesalahan ramalannya.

**Tabel 4.10** Akurasi Model ARIMAX-QR pada Data Simulasi Skenario 1

Replikasi	Metode	RMSE	MAE	MdAE
1	ARIMAX	1,1588	0,9633	0,7503
	ARIMAX-QR M.1	1,3354	1,0020	<b>0,7409</b>
	ARIMAX-QR M.2	<b>1,1181</b>	<b>0,9407</b>	0,9508
	ARIMAX-QR M.3	1,2071	0,9827	0,8203
	ARIMAX-QR M.4	1,2859	1,0380	0,9273
2	ARIMAX	1,8751	1,5018	1,3447
	ARIMAX-QR M.1	1,8897	1,5496	1,4558
	ARIMAX-QR M.2	<b>1,6726</b>	<b>1,2691</b>	<b>1,1280</b>
	ARIMAX-QR M.3	2,0132	1,6542	1,5381
	ARIMAX-QR M.4	1,7501	1,3936	1,2804
3	ARIMAX	1,9141	1,4100	1,0166
	ARIMAX-QR M.1	2,2663	1,4991	1,0401
	ARIMAX-QR M.2	1,9144	1,5124	1,0646
	ARIMAX-QR M.3	1,8155	1,2617	0,8534
	ARIMAX-QR M.4	<b>1,7460</b>	<b>1,1949</b>	<b>0,8129</b>
4	ARIMAX	1,2827	0,9517	0,7799
	ARIMAX-QR M.1	1,3054	0,9151	0,4275
	ARIMAX-QR M.2	1,4197	1,0900	0,9749
	ARIMAX-QR M.3	1,3266	0,9243	0,4941
	ARIMAX-QR M.4	<b>1,2691</b>	<b>0,8445</b>	<b>0,4229</b>
5	ARIMAX	1,4298	1,2356	1,0629
	ARIMAX-QR M.1	1,5258	1,3477	1,4102
	ARIMAX-QR M.2	<b>1,2269</b>	<b>1,0378</b>	<b>0,7316</b>
	ARIMAX-QR M.3	1,4183	1,1995	1,0254
	ARIMAX-QR M.4	1,6413	1,5067	1,5292
6	ARIMAX	<b>1,0989</b>	0,9754	0,9207
	ARIMAX-QR M.1	1,1116	0,8928	0,9107
	ARIMAX-QR M.2	1,2289	1,1145	0,9649
	ARIMAX-QR M.3	1,3064	1,2957	1,2417
	ARIMAX-QR M.4	<b>1,1338</b>	<b>0,9214</b>	<b>0,7837</b>
7	ARIMAX	1,4367	1,2707	1,2552
	ARIMAX-QR M.1	1,6557	1,3621	1,4156
	ARIMAX-QR M.2	1,3945	1,2420	1,2697
	ARIMAX-QR M.3	<b>1,3478</b>	<b>1,1880</b>	1,1356
	ARIMAX-QR M.4	1,4316	1,2689	<b>1,2126</b>
8	ARIMAX	<b>1,4849</b>	<b>1,0327</b>	<b>0,5146</b>
	ARIMAX-QR M.1	1,6922	1,2814	0,7470
	ARIMAX-QR M.2	1,5582	1,1667	0,8948
	ARIMAX-QR M.3	1,4801	1,0969	0,5519
	ARIMAX-QR M.4	1,6608	1,1777	0,6909

**Tabel 4.10** Akurasi Model ARIMAX-QR pada Data Simulasi Skenario 1  
(lanjutan)

Replikasi	Metode	RMSE	MAE	MdAE
9	ARIMAX	1,4908	1,3326	1,3279
	ARIMAX-QR M.1	1,2418	1,0674	1,2166
	ARIMAX-QR M.2	1,4506	1,3072	1,4319
	ARIMAX-QR M.3	<b>1,1362</b>	<b>1,0201</b>	<b>1,1398</b>
	ARIMAX-QR M.4	1,3734	1,2007	1,2255
10	ARIMAX	1,6712	1,3660	1,2137
	ARIMAX-QR M.1	2,2453	1,7685	1,4065
	ARIMAX-QR M.2	<b>1,6405</b>	<b>1,3364</b>	<b>1,1615</b>
	ARIMAX-QR M.3	2,0266	1,5359	1,1413
	ARIMAX-QR M.4	2,1251	1,5954	<b>1,1378</b>
Rata-rata	ARIMAX	1,4843	1,2040	1,0187
	ARIMAX-QR M.1	1,6269	1,2686	1,0771
	ARIMAX-QR M.2	<b>1,4624</b>	<b>1,2017</b>	1,0173
	ARIMAX-QR M.3	1,5078	1,2159	<b>0,9942</b>
	ARIMAX-QR M.4	1,5417	1,2142	1,0023

Pada data replikasi 1, nilai RMSE yang dihasilkan pada ramalan *out-sample* menggunakan metode ARIMAX adalah sebesar 1,158 sedangkan yang menggunakan metode ARIMAX-QR model 1 hingga model 4 masing-masing adalah 1,335, 1,118, 1,207 dan 1,286. Berdasarkan perbandingan RMSE, MAE, dan MdAE maka metode ARIMAX-QR model 2 menjadi model terbaik untuk memodelkan data skenario 1 replikasi 1. Dari Tabel 4.10, didapatkan bahwa metode ARIMAX-QR model 2 menjadi model terbaik untuk 4 dari 10 data replikasi yaitu data replikasi 1, 2, 5 dan 10, metode ARIMAX-QR model 3 menjadi model terbaik untuk 2 dari 10 data replikasi, model 4 sebanyak 3 data replikasi sedangkan model 1 tidak terpilih pada replikasi berapapun. Metode ARIMAX baik digunakan untuk memodelkan data replikasi 8. Apabila dilihat secara rata-rata, ARIMAX-QR model 2 menghasilkan kesalahan ramalan paling kecil dibanding metode lainnya.

Selain menghasilkan ramalan titik, dihasilkan pula ramalan interval dari tiap model yang digunakan. Kebaikan model dapat diperhatikan berdasarkan akurasi ramalan yakni berapa persen data yang masuk di dalam interval. Pada pemodelan menggunakan pedekatan kuantil menggunakan kuantil 0,025 sebagai batas bawah




dan kuantil 0,975 untuk batas atasnya. Akurasi ramalan interval dari tiap metode di tiap replikasi data skenario 1 disajikan pada Tabel 4.11 berikut.

**Tabel 4.11** Akurasi Ramalan Interval Model ARIMAX-QR pada Data Simulasi Skenario 1 (dalam persen)

Replikasi	ARIMAX	ARIMAX-QR			
		Model 1	Model 2	Model 3	Model 4
1	91,67	91,67	100,00	100,00	100,00
2	83,33	83,33	91,67	91,67	91,67
3	83,33	83,33	91,67	100,00	100,00
4	83,33	75,00	91,67	100,00	100,00
5	83,33	91,67	100,00	100,00	100,00
6	91,67	75,00	100,00	100,00	100,00
7	83,33	75,00	100,00	100,00	100,00
8	75,00	66,67	100,00	91,67	91,67
9	75,00	75,00	100,00	91,67	100,00
10	83,33	66,67	91,67	100,00	83,33
Rata-rata	83,33	78,33	96,67	97,50	96,67

Tabel 4.11 menunjukkan kebaikan model ARIMAX dan ARIMAX-QR berdasarkan akurasi data *out-sample* yang masuk di dalam interval. Metode klasik ARIMAX menghasilkan akurasi ramalan sebesar 83,33%. Metode ARIMAX-QR model 3 menghasilkan akurasi ramalan yang lebih besar dibanding model yang lain yakni sebesar 97,50%. Namun apabila diperhatikan kembali, ARIMAX-QR model 3 menghasilkan ramalan interval yang lebih lebar dibanding model lainnya. ARIMAX-QR model 2 dan 4 menghasilkan akurasi ramalan sebesar 96,67%. ARIMAX-QR model 2 menghasilkan ramalan interval yang lebih sempit dibandingkan ARIMAX-QR model 3, sehingga dapat dikatakan bahwa ARIMAX-QR model 2 menghasilkan ramalan yang lebih baik dibanding model yang lain, dimana akurasi ramalannya tinggi dengan interval yang tidak lebih lebar dibanding model lain. Hal ini sejalan dengan nilai RMSE dari ARIMAX-QR model 2 yang lebih kecil dibanding model yang lain dikarenakan lebih banyak titik yang masuk di dalam interval.



**Gambar 4.11** Rasio Kesalahan Ramalan Metode ARIMAX-QR terhadap metode ARIMAX pada Skenario 1

Gambar 4.11 menunjukkan perbandingan rasio kesalahan ramalan dari model ARIMAX-QR terhadap model ARIMAX pada peramalan data *out-sample* skenario 1. Pada Gambar 4.11 ditunjukkan bahwa pada beberapa replikasi pada skenario 1 yaitu data yang mengandung pola tren, musiman homogen dan variasi kalender dengan *error* yang linier, metode ARIMAX-QR mampu menurunkan nilai kesalahan ramalan dibanding model *benchmark* yang digunakan yaitu model ARIMAX baik berdasarkan kriteria RMSE, MAE dan MdAE.


#### 4.1.2 Studi Simulasi Skenario 2 (Varians Musiman Heterogen)

Pada skenario ini, data simulasi dibangkitkan dengan menambahkan data berpola tren, musiman, dan variasi kalender serta error linier. Untuk simulasi data dengan varians yang tidak homogen (heteroskedastisitas) ini, dilakukan dengan membangkitkan data berdistribusi Uniform untuk pola musiman dengan varians yang berbeda-beda sebagai berikut.


**Tabel 4.12** Bangkitan Data Simulasi untuk Pola Musiman Skenario 2

Bulan	$U(a,b)$	Bulan	$U(a,b)$
Januari	$U(20,23)$	Juli	$U(8,28)$
Februari	$U(22,27)$	Agustus	$U(11,23)$
Maret	$U(24,26)$	September	$U(14,17)$
April	$U(23,24)$	Oktober	$U(13,19)$
Mei	$U(19,26)$	November	$U(13,21)$
Juni	$U(15,25)$	Desember	$U(17,22)$

Tabel 4.12 menyajikan parameter dari distribusi Uniform yang digunakan untuk membangkitkan pola musiman non-homogen pada skenario 2. Pada tabel tersebut ditunjukkan bahwa varians dari tiap-tiap bulan memiliki besaran yang berbeda. Misal pada bulan Januari akan dibangkitkan data dalam *range* 20 hingga 23, memiliki range nilai 3, sedangkan pada bulan Februari data dibangkitkan dalam *range* 22 hingga 27, memiliki range nilai 5. Pola musiman non-homogen yang dihasilkan dari data bangkitan tersebut disajikan pada Gambar 4.12.

**Gambar 4.12** Plot Jangkauan Pola Musiman Non-homogen Data Simulasi Skenario 2


Gambar 4.12 menunjukkan jangkauan dari pola musiman non-homogen yang digunakan pada simulasi skenario 2. Dengan menggabungkan data tetap pada Gambar 4.1 dengan pola yang ditunjukkan pada Gambar 4.12, maka berikut adalah plot *time series* dan *boxplot* dari data yang mengandung pola tren, musiman non-homogen, variasi kalender dan error linier. Skenario ini dilakukan replikasi sebanyak lima kali dengan membangkitkan kembali berpola musiman dan error linier di tiap replikasinya.



**Gambar 4. 13** Plot *Time Series* Data (a), dan Boxplot dari Data yaitu yang Dikategorikan Tiap Bulan (b) serta Setelah Dihilangkan Pola Tren dan Variasi Kalender (c), dari Data Simulasi Skenario 2

Berdasarkan Gambar 4.10(b) bahwa apabila dilihat berdasarkan bulan, maka variasi dari data pada tiap-tiap bulan terutama pada bulan Juli hingga Oktober nampak heterogen, dimana pada bulan-bulan ini variansnya lebih besar dibanding bulan-bulan lainnya. Setelah dihilangkan efek pola tren dan variasi kalendernya seperti pada gambar (c), varians dari tiap-tiap bulan terlihat masih heterogen. Hal ini menunjukkan bahwa pola musiman pada tiap bulan di simulasi ini tidak homogen, hal ini menunjukkan skenario yang dilakukan sudah sesuai.

Metode pertama yang digunakan adalah *time series regression*. Hasil yang diperoleh dari *time series regression* pada data simulasi menunjukkan bahwa data tidak memenuhi asumsi *white noise* (independen dan homogen) serta berdistribusi normal.



**Gambar 4.14** Plot ACF dan PACF Residual Model TSR Skenario 2 Replikasi 1

Pada plot ACF dan PACF yang ditunjukkan pada Gambar 4.14, nampak bahwa masih terdapat lag-lag yang keluar batas (signifikan). Hal ini mengindikasikan residual model TSR masih belum memenuhi asumsi *white noise*. Oleh karena itu dilakukan pemodelan pada residual model TSR menggunakan model ARIMA dan diperoleh hasil sebagai berikut.

**Tabel 4.13** Estimasi dan Signifikansi Parameter Model ARIMA Residual TSR Simulasi Skenario 2

Replikasi	Model ARIMA	Koefisien Model	Std. Error	P-Value
1	ARIMA(1,0,0)	$\phi_1 = 0,1789$	0,0735	0,0159
2	ARIMA(1,0,0)	$\phi_1 = 0,2249$	0,0724	0,0018
3	ARIMA(1,0,0)	$\phi_1 = 0,2156$	0,0726	0,0029
4	ARIMA(1,0,0)	$\phi_1 = 0,2922$	0,0711	0,0000
5	ARIMA(1,0,0)	$\phi_1 = 0,2123$	0,0729	0,0036
6	ARIMA(1,0,0)	$\phi_1 = 0,1227$	0,0738	0,0464
7	ARIMA(1,0,0)	$\phi_1 = 0,2699$	0,0716	0,0001
8	ARIMA(1,0,0)	$\phi_1 = 0,1279$	0,0737	0,0428
9	ARIMA(1,0,0)	$\phi_1 = 0,1773$	0,0732	0,0154
10	ARIMA(1,0,0)	$\phi_1 = 0,3019$	0,0708	0,0000


Tabel 4.13 menunjukkan nilai koefisien pada tiap model ARIMA menghasilkan p-value kurang dari 0,05 yang berarti Tolak  $H_0$  yang berarti koefisien parameternya signifikan. Tahapan selanjutnya adalah menguji pemenuhan asumsi *white noise* dan distribusi normal dari residual model ARIMA yang dihasilkan yang disajikan pada Tabel 4.14.

**Tabel 4.14** Pemenuhan Asumsi Model ARIMA Residual TSR Simulasi Skenario 2

Replikasi	Model ARIMA	Pemenuhan Asumsi Residual Model ARIMA	
		White Noise	Distribusi Normal
1	ARIMA(1,0,0)	✓	✓
2	ARIMA(1,0,0)	✓	✓
3	ARIMA(1,0,0)	✓	✓
4	ARIMA(1,0,0)	✓	✓
5	ARIMA(1,0,0)	✓	✓
6	ARIMA(1,0,0)	✓	✓
7	ARIMA(1,0,0)	✓	✓
8	ARIMA(1,0,0)	✓	✓
9	ARIMA(1,0,0)	✓	✓
10	ARIMA(1,0,0)	✓	✓
✓ = Terpenuhi			


Asumsi *white noise* dan distribusi normal dari residual ARIMA telah terpenuhi, seperti yang ditunjukkan pada Tabel 4.13, tahapan selanjutnya adalah melakukan ramalan data *out-sample*. Dilakukan peramalan data *out-sample* sebanyak 12 data, yang kemudian dihitung nilai akurasi ramalannya.

Selanjutnya akan diterapkan model *hybrid ARIMAX-Quantile Regression* model 1 untuk pemodelan data simulasi skenario 2 yaitu menambahkan nilai ramalan model ARIMA data *in-sample* menjadi salah satu variabel prediktor pada *Time Series regression* menggunakan *quantile regression*. Sebelum membentuk model ARIMA, tahapan pertama yang dilakukan adalah identifikasi model yaitu menguji stasioner data. Berikut adalah plot ACF data simulasi skenario 2 replikasi 1.



**Gambar 4.15** Plot ACF Data Simulasi Skenario 2 Replikasi 1

Berdasarkan Gambar 4.15, ACF membentuk pola turun lambat. Hal ini menunjukkan bahwa data belum stasioner pada *mean*, sehingga perlu dilakukan *differencing* pada data. Plot ACF dan PACF setelah dilakukan *differencing* non-musiman adalah sebagai berikut.



**Gambar 4.16** Plot ACF Dan PACF Data Simulasi Skenario 2 Replikasi 1  
Setelah *Differencing*

Setelah dilakukan *differencing* maka data sudah memenuhi asumsi stasioner dalam *mean* yang ditunjukkan pada Gambar 4.13 dimana plot ACF mempunyai pola turun cepat atau *cut off*. Dari plot ACF dan PACF yang diperoleh kemudian ditentukan model dugaan ARIMA yang akan digunakan. Dilakukan prosedur identifikasi yang sama untuk replikasi 2 hingga 5. Dugaan model ARIMA untuk semua data pada skenario 2 serta hasil pengujian signifikansi parameter dan asumsi residual disajikan pada Tabel 4.15 berikut.

**Tabel 4.15** Hasil Pengujian Signifikansi Parameter Model ARIMA Skenario 2

Replikasi	Model ARIMA	Signifikansi Parameter	Uji White Noise	Uji Normalitas
1	$([23],1,1)(0,0,1)^{12}$	✓	✓	×
2	$([23],1,1)(0,0,1)^{12}$	✓	✓	×
3	$([23],1,1)(0,0,1)^{12}$	✓	✓	×
4	$([11,23],1,1)(0,0,1)^{12}$	✓	✓	×
5	$([23],1,1)(0,0,1)^{12}$	✓	✓	×
6	$([23],1,1)(0,0,1)^{12}$	✓	✓	×
7	$([23],1,1)(0,0,1)^{12}$	✓	✓	×
8	$([11,23],1,1)(0,0,1)^{12}$	✓	✓	×
9	$([23],1,1)(0,0,1)^{12}$	✓	✓	×
10	$([23],1,1)(0,0,1)^{12}$	✓	✓	×

Hasil yang disajikan pada Tabel 4.15 menunjukkan bahwa model dugaan telah memenuhi asumsi *white noise* namun tidak berdistribusi normal. Setelah didapatkan model ARIMA yang sesuai untuk masing-masing data kemudian dilakukan peramalan untuk data *in-sample* yang kemudian akan menjadi salah satu variabel prediktor bersama variabel *dummy* untuk *time s*

*eries regression* menggunakan regresi kuantil. Hasil regresi kuantil antara data simulasi skenario 2 replikasi 1 untuk kuantil 0,025, 0,50 dan 0,975 disajikan pada Tabel 4.16 berikut.

**Tabel 4.16** Estimasi Koefisien ARIMAX-QR Model 1 Data Dimulasi Skenario 2 Replikasi 1

$\tau$	0,025	0,50	0,975
$t$	0,1296	0,1497	0,1394
$M_{1,t}$	14,2406	20,8055	21,3589
$M_{2,t}$	17,4474	24,7814	25,2648
$M_{3,t}$	18,0143	24,4311	25,0724
$M_{4,t}$	17,4747	23,1203	23,9929
$M_{5,t}$	15,4231	22,9996	24,1978
$M_{6,t}$	12,5152	20,8161	23,1912
$M_{7,t}$	4,7639	20,7590	26,0439
$M_{8,t}$	7,1907	16,8882	19,8814
$M_{9,t}$	8,3550	15,2275	16,0352



**Tabel 4.16** Estimasi Koefisien ARIMAX-QR Model 1 Data Dimulasi Skenario  
2 Replikasi 1 (lanjutan)


$\tau$	0,025	0,50	0,975
$M_{10,t}$	9,1504	15,2302	16,1367
$M_{11,t}$	7,5489	17,7584	19,7059
$M_{12,t}$	11,0029	18,6735	19,4183
$V_{1,t}$	8,2657	8,4699	8,3316
$V_{2,t}$	17,0887	16,0671	14,8359
$V_{3,t}$	23,8174	20,8664	24,7426
$V_{4,t}$	30,9496	29,3089	29,5694
$V_{1,t-1}$	26,9166	29,4889	26,1873
$V_{2,t-1}$	18,1509	18,5782	14,9365
$V_{3,t-1}$	11,3660	10,5332	8,5075
$V_{4,t-1}$	6,9752	6,0769	3,2077
	(0,0000)	(0,0003)	(0,0001)
$\hat{Z}_t$	0,1861	0,0126	0,0906
	(0,0000)	(0,8676)	(0,0108)

**Keterangan:** Semua nilai signifikansi parameter bernilai 0.0000, kecuali yang diberi tanda (...)

Pada Tabel 4.16 ditunjukkan nilai estimasi untuk koefisien regresi kuantil pada kuantil 0,025, 0,5 dan 0,975 untuk semua variabel independen. Model ARIMAX-QR yang terbentuk untuk kuantil 0,50 adalah sebagai berikut.

$$\begin{aligned}
 Y_{2,1,t}(0,5) = & 0,145 t + 20,8055 M_{1,t} + 24,781 M_{2,t} + 24,431 M_{3,t} + 23,120 M_{4,t} + \\
 & 22,999 M_{5,t} + 20,816 M_{6,t} + 20,759 M_{7,t} + 16,888 M_{8,t} + 15,227 M_{9,t} + \\
 & 15,230 M_{10,t} + 17,758 M_{11,t} + 18,673 M_{12,t} + 8,469 V_{1,t} + 16,067 V_{2,t} + \\
 & 20,866 V_{3,t} + 29,309 V_{4,t} + 29,489 V_{1,t-1} + 18,578 V_{2,t-1} + 10,533 V_{3,t-1} + \\
 & 6,077 V_{4,t-1} + 0,013 \hat{Z}_{2,1,t} + \varepsilon_t
 \end{aligned}$$

Model inilah yang kemudian digunakan untuk meramalkan data *out-sample*. Plot nilai prediksi untuk data *in-sample* dan data *out-sample* disajikan pada Gambar 4.17.



**Gambar 4.17** Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 2 menggunakan ARIMAX-QR Model 1

Langkah yang sama dilakukan ulang untuk data replikasi 2 hingga 10. ARIMAX-QR model 2 juga diterapkan pada data simulasi ini dengan menggunakan nilai prediksi metode ARIMAX dari  $Y_t$  dilambangkan dengan  $\hat{Z}_t^*$  sebagai prediktor dalam regresi kuantil. Hasil regresi kuantil yang diperoleh adalah sebagai berikut.


**Tabel 4.17** Estimasi Parameter ARIMAX-QR Model 2 Residual Data Replikasi 1 Skenario 2

Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$\hat{Z}_{2,1,t}^*$	0,856	0,000	0,9998	0,000	1,141	0,000

Dari hasil yang diperoleh ini maka untuk  $\tau = 0,50$  model yang terbentuk adalah sebagai berikut.

$$Y_{2,1,t} = 0,999\hat{Z}_{2,1,t}^* + \varepsilon_t.$$

Dengan menggunakan model ini, kemudian dilakukan peramalan untuk data *in-sample* dan *out-sample*



**Gambar 4. 18** Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 2 menggunakan ARIMAX-QR Model 2

Selanjutnya dilakukan pemodelan menggunakan ARIMAX-QR model 3 yaitu melakukan dekomposisi terlebih dahulu terhadap data, kemudian melakukan regresi kuantil pada residual model dekomposisi dengan variabel prediktornya meliputi lag-lag dari residual tersebut dan nilai prediksi ARIMA dari data. Pada plot PACF dari residual model dekomposisi yang telah stasioner, didapatkan bahwa lag 1 signifikan, oleh karena itu lag 1 dari residual ( $a_{t-1}$ ) akan dijadikan variabel prediktor dalam regresi kuantil. Hasil regresi kuantil dari residual model dekomposisi disajikan pada Tabel 4.18.

**Tabel 4.18** Estimasi Parameter Model Regresi Kuantil Residual Data Replikasi 1 Skenario 2


Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$a_{t-1}$	-0,014	0,929	0,226	0,001	0,237	0,000
$\hat{Z}_t$	-0,144	0,000	-0,001	0,922	0,135	0,000

Tabel 4.18 menunjukkan nilai estimasi untuk koefisien regresi kuantil pada kuantil 0,025, 0,50 dan 0,975 untuk variabel prediktor yang digunakan. Model yang terbentuk pada kuantil 0,50 adalah sebagai berikut.


$$Y_{2,1,t} = 0,150 t + 21,137 M_{1,t} + 25,028 M_{2,t} + 25,073 M_{3,t} + 23,838 M_{4,t} + 23,306 M_{5,t} + 20,839 M_{6,t} + 19,396 M_{7,t} + 17,112 M_{8,t} + 15,629 M_{9,t} + 14,986 M_{10,t} + 17,354 M_{11,t} + 18,843 M_{12,t} + 9,381 V_{1,t} + 16,931 V_{2,t} + 22,716 V_{3,t} + 31,531 V_{4,t} + 29,551 V_{1,t-1} + 20,006 V_{2,t-1} + 10,090 V_{3,t-1} + 6,492 V_{4,t-1} + \hat{a}_{2,1,t}(\tau) + \varepsilon_t$$

Untuk  $\tau = 0,50$ ,  $\hat{a}_{2,1,t}(\tau) = 0,226a_{2,1,t-1} - 0,001\hat{Z}_{2,1,t} + \varepsilon_t$ .

Model inilah kemudian yang digunakan untuk meramalkan data *out-sample*. Plot nilai prediksi untuk data *in-sample* dan data *out-sample* disajikan pada Gambar 4.19.



**Gambar 4.19** Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 3



**Gambar 4.19** Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 3 (lanjutan)

ARIMAX-QR jenis ke empat adalah melakukan regresi kuantil antara data ( $Y_t$ ) dengan prediktor yang meliputi nilai prediksi model TSR ( $\hat{Y}_t^{(1)}$ ) dan lag dari  $Y_t$ . Berdasarkan plot PACF residual, didapatkan bahwa lag 1 signifikan, sehingga lag 1 ( $Y_{t-1}$ ) dijadikan variabel prediktor pada model ini. Hasil regresi kuantil dari model ini adalah sebagai berikut.

Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$\hat{Y}_{2,1,t}^{(1)}$	0,991	0,000	1,016	0,000	1,033	0,000
$Y_{2,1,t-1}$	-0,155	0,003	-0,016	0,382	0,111	0,030


Model yang terbentuk untuk  $\tau = 0,50$  dapat dituliskan seperti berikut.

$$Y_{2,1,t} = 1,016\hat{Y}_{2,1,t}^{(1)} - 0,016Y_{2,1,t-1} + \varepsilon_t$$

dengan,

$$\begin{aligned} \hat{Y}_{2,1,t}^{(1)} = & 0,150 t + 21,137 M_{1,t} + 25,028 M_{2,t} + 25,073 M_{3,t} + 23,838 M_{4,t} + \\ & 23,306 M_{5,t} + 20,839 M_{6,t} + 19,396 M_{7,t} + 17,112 M_{8,t} + 15,629 M_{9,t} + \\ & 14,986 M_{10,t} + 17,354 M_{11,t} + 18,843 M_{12,t} + 9,381 V_{1,t} + 16,931 V_{2,t} + \\ & 22,716 V_{3,t} + 31,531 V_{4,t} + 29,551 V_{1,t-1} + 20,006 V_{2,t-1} + 10,090 V_{3,t-1} + \\ & 6,492 V_{4,t-1}. \end{aligned}$$

Model ini kemudian digunakan untuk meramalkan data *in-sample* dan *out-sample* dengan hasil sebagai berikut.



**Gambar 4.20** Plot Nilai Aktual dan Ramalan pada Data Simulasi Skenario 1 menggunakan ARIMAX-QR Model 4

Dari sepuluh replikasi yang telah dilakukan dan dianalisis menggunakan cara yang sama yaitu dilakukan analisis menggunakan metode ARIMAX dan model *hybrid* ARIMAX-QR model 1 hingga model 4. Selanjutnya dihitung nilai rata-rata akurasi untuk data *testing* dari kesepuluh replikasi. Hasil perhitungan kesalahan ramalan data *out-sample* pada tiap replikasi data skenario 2 menggunakan tiap model dapat disajikan pada Tabel 4.19 berikut.

**Tabel 4.19** Akurasi Model ARIMAX-QR pada Data Simulasi Skenario 2

Replikasi	Metode	RMSE	MAE	MdAE
1	ARIMAX	2,1186	1,7105	1,5268
	ARIMAX-QR M.1	2,4781	1,9510	1,6260
	ARIMAX-QR M.2	<b>2,0273</b>	1,6565	1,4272
	ARIMAX-QR M.3	<b>2,0678</b>	<b>1,5718</b>	<b>1,1314</b>
	ARIMAX-QR M.4	2,1503	1,7457	1,5783
2	ARIMAX	2,2468	1,6187	1,1673
	ARIMAX-QR M.1	<b>2,1542</b>	1,4375	0,9222
	ARIMAX-QR M.2	<b>2,2403</b>	<b>1,4388</b>	<b>0,8424</b>
	ARIMAX-QR M.3	2,3238	1,6381	1,1545
	ARIMAX-QR M.4	2,3141	1,6315	1,1309
3	ARIMAX	2,2801	1,7058	1,0833
	ARIMAX-QR M.1	2,3400	1,8480	1,7340
	ARIMAX-QR M.2	2,2732	1,6939	1,1293
	ARIMAX-QR M.3	<b>2,2619</b>	1,6904	1,1909
	ARIMAX-QR M.4	<b>2,2874</b>	<b>1,6837</b>	<b>1,1268</b>
4	ARIMAX	<b>4,1417</b>	2,9266	2,1430
	ARIMAX-QR M.1	4,2148	3,1150	2,3827
	ARIMAX-QR M.2	<b>4,2616</b>	<b>2,9252</b>	<b>1,8620</b>
	ARIMAX-QR M.3	4,1979	3,0503	2,2000
	ARIMAX-QR M.4	4,2280	2,9594	2,1942
5	ARIMAX	<b>2,2336</b>	<b>1,8152</b>	1,9119
	ARIMAX-QR M.1	2,5042	2,0806	1,9135
	ARIMAX-QR M.2	2,2531	1,8629	<b>1,6465</b>
	ARIMAX-QR M.3	2,2831	1,9110	1,7082
	ARIMAX-QR M.4	2,2607	1,8975	1,7492
6	ARIMAX	5,2053	3,9786	2,8563
	ARIMAX-QR M.1	5,9448	4,4580	3,2088
	ARIMAX-QR M.2	5,1005	3,9126	2,8626
	ARIMAX-QR M.3	<b>5,0616</b>	<b>3,8131</b>	<b>2,5816</b>
	ARIMAX-QR M.4	5,1266	3,8415	2,6834
7	ARIMAX	3,0517	2,1994	1,4718
	ARIMAX-QR M.1	3,6379	2,6572	1,5049
	ARIMAX-QR M.2	<b>2,7222</b>	<b>2,0113</b>	<b>1,4298</b>
	ARIMAX-QR M.3	3,0230	2,2546	1,9131
	ARIMAX-QR M.4	<b>2,9666</b>	2,1440	1,4547

**Tabel 4.19** Akurasi Model ARIMAX-QR pada Data Simulasi Skenario 2  
(lanjutan)

Replikasi	Metode	RMSE	MAE	MdAE
8	ARIMAX	3,7559	2,7725	<b>1,9933</b>
	ARIMAX-QR M.1	4,4128	3,1788	2,2917
	ARIMAX-QR M.2	<b>3,7434</b>	<b>2,7627</b>	<b>1,9848</b>
	ARIMAX-QR M.3	3,8154	2,9026	2,0598
	ARIMAX-QR M.4	3,8641	2,8353	2,1291
9	ARIMAX	3,7771	2,7395	1,7524
	ARIMAX-QR M.1	<b>3,5088</b>	2,6121	2,0082
	ARIMAX-QR M.2	3,5434	<b>2,6050</b>	<b>1,7198</b>
	ARIMAX-QR M.3	3,7894	2,8120	1,8836
	ARIMAX-QR M.4	3,7528	2,7435	1,7239
10	ARIMAX	<b>2,1942</b>	<b>1,8027</b>	1,7153
	ARIMAX-QR M.1	2,3505	1,9132	1,9485
	ARIMAX-QR M.2	2,2183	1,8373	<b>1,7152</b>
	ARIMAX-QR M.3	2,7610	2,3318	1,9821
	ARIMAX-QR M.4	2,3883	1,9425	1,7181
Rata-rata	ARIMAX	3,1005	2,3269	1,7621
	ARIMAX-QR M.1	3,3546	2,5251	1,9540
	ARIMAX-QR M.2	<b>3,0383</b>	<b>2,2706</b>	<b>1,6620</b>
	ARIMAX-QR M.3	3,1585	2,3976	1,7805
	ARIMAX-QR M.4	3,1339	2,3425	1,7489

Pada Tabel 4.19 menunjukkan kesalahan ramalan titik pada pemodelan data skenario 2. Dari perbandingan ketida model yang digunakan, didapatkan hasil bahwa metode ARIMAX-QR model 2 menjadi model terbaik untuk memodelkan 4 dari 10 data replikasi skenario 2. Metode ARIMAX-QR model 1 tidak terpilih menjadi model terbaik pada replikasi berapapun, sedangkan model 3 menjadi model terbaik untuk 2 replikasi dan model 4 pada 3 replikasi. Apabila dilihat secara rata-rata, metode ARIMAX-QR model 2 menghasilkan kesalahan ramalan lebih kecil dibanding model lainnya.

Selain berdasarkan ramalan titik, kebaikan model dapat diperhatikan berdasarkan akurasi ramalan yakni berapa persen data yang masuk di dalam interval. Pada pemodelan menggunakan pedekatan kuantil menggunakan kuantil 0,025 sebagai batas bawah




dan kuantil 0,975 untuk batas atasnya. Akurasi ramalan interval dari tiap metode di tiap replikasi data skenario 2 disajikan pada Tabel 4.20 berikut.

**Tabel 4.20** Akurasi Ramalan Interval Model ARIMAX-QR pada Data Simulasi Skenario 2 (dalam persen)

Replikasi	ARIMAX	ARIMAX-QR			
		Model 1	Model 2	Model 3	Model 4
1	100,00	91,67	100,00	83,33	100,00
2	100,00	100,00	100,00	83,33	91,67
3	100,00	100,00	100,00	75,00	100,00
4	83,33	91,67	91,67	41,67	100,00
5	100,00	100,00	100,00	91,67	100,00
6	83,33	50,00	83,33	75,00	100,00
7	91,67	75,00	100,00	83,33	100,00
8	83,33	66,67	83,33	91,67	91,67
9	83,33	58,33	91,67	66,67	100,00
10	91,67	100,00	100,00	41,67	83,33
Rata-rata	91,67	83,33	95,00	73,33	96,67

Pada Tabel 4.20 disajikan nilai kebaikan model ARIMAX dan ARIMAX-QR berdasarkan akurasi data *out-sample* yang masuk di dalam interval pada data skenario 2 yakni data yang mengandung pola tren, musiman non-homogen dan variasi kalender dengan *error* linier. Metode klasik ARIMAX menghasilkan akurasi ramalan sebesar 91,67%. Pada data skenario 2 ini, ARIMAX-QR model 3 menghasilkan interval yang paling sempit dibanding model yang lain, sehingga mengakibatkan akurasi ramalannya lebih kecil dibanding model lain. Metode ARIMAX-QR model 4 menghasilkan akurasi ramalan yang lebih besar dibanding model yang lain yakni sebesar 96,67% namun model ini menghasilkan ramalan interval yang lebih lebar dibanding model lainnya. Apabila memperhatikan nilai akurasi ramalan titiknya, ARIMAX-QR model 2 menghasilkan RMSE paling kecil dibanding model lainnya, hal ini sejalan dengan nilai akurasi sebesar 95,00% yang menandakan bahwa banyak titik yang masuk di dalam interval.




**Gambar 4.21** Rasio Kesalahan Ramalan Metode ARIMAX-QR terhadap metode ARIMAX pada Skenario 2

Gambar 4.21 menunjukkan plot perbandingan rasio kesalahan ramalan metode ARIMAX-QR tiap model terhadap metode *benchmark* yaitu ARIMAX. Pada data skenario 2 yaitu data yang mengandung pola tren, musiman non-homogen, variasi kalender dan error yang linier, metode ARIMAX-QR mampu menghasilkan nilai kesalahan ramalan yang lebih kecil dibanding metode klasik ARIMAX. Nilai kesalahan ramalan yang dihasilkan oleh ARIMAX-QR model 1 cenderung lebih tinggi dibanding ARIMAX dan ARIMAX-QR model lainnya. Hal ini diduga karena masih terlibatnya variabel *dummy* pada pemodelan, dimana seharusnya model regresi kuantil melibatkan data yang kontinu, sedangkan variabel *dummy* adalah data yang diskrit (0 dan 1) sehingga menghasilkan ramalan yang kurang baik pada data yang heterogen. Berbeda halnya pada skenario 1 yang menunjukkan bahwa model ini menghasilkan akurasi ramalan yang tidak jauh beda dengan model lainnya karena pada skenario 1 data mengandung pola musiman yang homogen.

## 4.2 Karakteristik Data *Inflow* dan *Outflow* Uang Kartal di Jawa Timur

Sebelum melakukan peramalan maka terlebih dahulu mendeskripsikan data *inflow* dan *outflow* uang kartal di Jawa Timur. Pola kenaikan *inflow* dan *outflow* uang kartal di Jawa Timur, dapat dilihat pada Gambar 4.22.



**Gambar 4.22** Pola Kenaikan *Inflow* dan *Outflow* di Jawa Timur

*Inflow* dan *outflow* uang kartal di Jawa Timur menunjukkan pola yang sama yaitu terbentuknya beberapa pola selama periode data yang diamati. Terdapat tiga periode yang berbeda selama pengamatan. Dari tahun 2003 hingga 2006, *inflow* dan *outflow* uang kartal mengalami kenaikan meskipun sempat menurun pada tahun 2007. Hal ini terjadi karena adanya kebijakan Bank Indonesia yaitu PBI Nomor 6/14/PBI/2004, dimana Bank Indonesia menerapkan uji coba setoran dan bayaran oleh perbankan. Dalam peraturan tersebut, perbankan hanya diperkenankan untuk menyetor uang dalam kondisi tidak layak edar (UTLE) dan sementara penarikan uang layak edar (ULE) dari Bank Indonesia hanya dapat dilakukan setelah jumlah dan pecahan tertentu ULE diperbankan sudah tidak tersedia. Pada kondisi seperti ini, apabila suatu bank mengalami posisi kelebihan atau kekurangan uang kartal pada pecahan tertentu, maka akan terjadi transaksi uang kartal antar bank. Akibatnya jumlah *inflow* dan


*outflow* di Bank Indonesia wilayah Jawa Timur menurun pada tahun 2007. Perubahan pola kedua terjadi pada periode tahun 2007 hingga tahun 2010 karena adanya perubahan kebijakan Bank Indonesia PBI Nomor 9/10/PBI/2007. Periode perubahan pola data ketiga terjadi pada tahun 2011 hingga 2016 yang disebabkan dengan diberlakukannya kembali peraturan UU No.7 Tahun 2011 mengenai penyetoran ULE ke Bank Indonesia yang menyebabkan terjadinya peningkatan jumlah *inflow* dan *outflow* yang cukup tinggi hingga tahun 2016. Hal ini menunjukkan bahwa kebijakan-kebijakan yang diterapkan oleh Bank Indonesia memberikan efek terhadap jumlah uang yang beredar di masyarakat.

**Tabel 4.21** Statistika Deskriptif (Miliar Rupiah)

Variabel	Rata-rata	St.Dev	Minimum	Maksimum
<i>Inflow</i>	3.658,97	2.240,74	824,22	14.403,88
<i>Outflow</i>	3.277,66	2.481,94	343,02	18.099,01


Rata-rata *inflow* di Jawa Timur dari tahun 2003 hingga 2016 adalah sebesar 3.658,97 miliar rupiah dengan standar deviasi 2.240,74 miliar rupiah. *Inflow* minimum di Jawa Timur masing-masing 824,22 miliar rupiah yang terjadi pada Juni 2009 dan nilai *inflow* maksimumnya sebesar 14.403,88 miliar rupiah yang terjadi Juli 2016. Untuk data *outflow* di Jawa Timur, didapatkan nilai rata-ratanya sebesar 3.277,66 miliar rupiah dengan standar deviasi sebesar 2.481,94 miliar rupiah. Nilai *outflow* minimum sebesar 343,02 miliar rupiah yang terjadi Januari 2009, dan nilai *outflow* maksimum sebesar 18.099,01 miliar rupiah yang terjadi Juni 2016.

Kenaikan jumlah kebutuhan uang di masyarakat diduga dipengaruhi oleh faktor-faktor musiman dan kejadian-kejadian tertentu seperti terjadinya Hari Raya Idul Fitri. Tanggal terjadinya Hari Raya Idul Fitri dari tahun 2003 hingga tahun 2016 dapat dilihat pada Tabel 3.2. Berdasarkan tanggal dan bulan terjadinya Hari Raya Idul Fitri tersebut dapat diketahui bahwa kenaikan *inflow* dan *outflow* dipengaruhi oleh bulan-bulan terjadinya Hari Raya Idul Fitri.



**Gambar 4.23** Boxplot *Inflow* di Jawa Timur

Gambar 4.23 menunjukkan nilai rata-rata *inflow* yang ditunjukkan dengan garis merah mengalami cenderung mengalami peningkatan pada bulan Januari, Agustus, September, Oktober dan November. Peningkatan *inflow* bulan Januari terjadi akibat adanya perayaan Natal dan Tahun Baru pada bulan sebelumnya, sehingga masyarakat cenderung menyetorkan uangnya setelah melakukan perayaan tersebut. Peningkatan *inflow* yang terjadi pada bulan Agustus, September, Oktober dan November terjadi dikarenakan terjadinya Hari Raya Idul Fitri pada bulan-bulan tersebut dalam periode waktu yang diamati. Berikut adalah *Time Series plot inflow* di Jawa Timur.




**Gambar 4.24** *Time Series Plot Inflow* di Jawa Timur

Kenaikan *inflow* terjadi pada bulan Januari (bulan 1) dan pada bulan-bulan terjadinya Hari Raya Idul Fitri yang ditandai dengan titik hijau serta satu bulan setelah terjadinya Hari Raya Idul Fitri yang ditandai dengan titik biru. Hal ini berkaitan dengan kecenderungan masyarakat yang menyetorkan uangnya setelah melakukan perayaan Hari Raya Idul Fitri. Dari sini ditunjukkan bahwa *inflow* uang kartal dipengaruhi oleh faktor musiman dan variasi kalender yaitu Hari Raya Idul Fitri, dimana waktu terjadinya Hari Raya Idul Fitri terjadi berdasarkan penanggalan bukan masehi, sehingga terjadi pergeseran tanggal setiap tahunnya. Kenaikan nilai *inflow* di Jawa Timur terjadi pada bulan-bulan berikut.

- Bulan Desember pada tahun 2003,
- Bulan November pada tahun 2004, 2005 dan 2006,
- Bulan Oktober pada tahun 2007, 2008 dan 2009,
- Bulan September pada tahun 2010, 2011, dan 2012,
- Bulan Agustus pada tahun 2013 dan 2014, dan
- Bulan Juli pada tahun 2015 dan 2016.

Rata-rata kenaikan *inflow* pada saat dan satu bulan setelah terjadinya Hari Raya Idul Fitri berdasarkan minggu terjadinya Hari Raya Idul Fitri pada periode tahun 2003 hingga 2016 di Jawa Timur disajikan pada Gambar 4.25 berikut.




**Gambar 4.25** Rata-rata *Inflow* pada Saat dan Setelah Hari Raya Idul Fitri

Berdasarkan Gambar 4.25 ditunjukkan bahwa pola kenaikan *inflow* pada saat dan satu bulan setelah terjadinya Hari Raya Idul Fitri berdasarkan minggu terjadinya Hari Raya Idul Fitri adalah sebagai berikut.

- a. Apabila Hari Raya Idul Fitri terjadi pada minggu pertama maka rata-rata *inflow* tinggi pada bulan tersebut. Rata-rata *inflow* pada bulan dimana terjadi Hari Raya Idul Fitri adalah 8.934,499 miliar rupiah. Rata-rata *inflow* menurun pada satu bulan setelah terjadinya Hari Raya Idul Fitri menjadi sebesar 4.135,898 miliar rupiah.
- b. Apabila Hari Raya Idul Fitri terjadi pada minggu kedua maka rata-rata *inflow* akan tinggi pada bulan terjadinya Hari Raya Idul Fitri dibanding satu bulan setelahnya. Rata-rata *inflow* pada bulan terjadinya Hari Raya Idul Fitri adalah sebesar 6.311,407 miliar rupiah, sedangkan satu bulan setelahnya rata-ratanya menurun menjadi 3.282,895 miliar rupiah.
- c. Apabila Hari Raya Idul Fitri terjadi pada minggu ketiga, rata-rata *inflow* pada bulan terjadinya Hari Raya Idul Fitri dan satu bulan setelahnya hampir sama. Tercatat rata-rata *inflow* di Jawa Timur pada saat terjadinya Hari Ray Idul Fitri sebesar 5.747,105 miliar rupiah dan sebesar 6.062,261 pada satu bulan setelahnya.
- d. Apabila Hari Raya Idul Fitri terjadi pada minggu keempat maka rata-rata *inflow* akan tinggi pada satu bulan setelah terjadinya Hari Raya Idul Fitri. Pada saat terjadinya Idul Fitri, tercatat nilai rata-rata *inflow* sebesar 2.315,101 miliar rupiah, dan meningkat tajam menjadi 8.455,737 miliar rupiah pada bulan selanjutnya.

*Outflow* memiliki pola kenaikan yang berbeda dengan *inflow*. Data *outflow* mengalami peningkatan pada bulan saat terjadinya Hari Raya Idul Fitri dan satu bulan sebelum terjadinya Idul Fitri. Hal ini disebabkan oleh permintaan uang serta kecenderungan masyarakat menarik uang sebelum melakukan perayaan Hari Raya

Idul Fitri cukup besar. Untuk lebih jelasnya dapat dilihat pada *Time Series plot* data *outflow* uang kartal di Jawa Timur berikut.



**Gambar 4.26** *Time Series Plot Outflow* di Jawa Timur


Gambar 4.26 menunjukkan pola *outflow* uang kartal di Jawa Timur pada periode Januari 2003 hingga Desember 2016. Peningkatan *outflow* di Jawa Timur terjadi pada bulan Desember (bulan 12) yaitu karena adanya perayaan natal dan tahun baru. Selain bulan Desember, *outflow* juga tinggi pada bulan saat terjadinya Hari Raya Idul Fitri yang ditandai dengan titik berwarna hijau serta satu bulan sebelum terjadinya Hari Raya Idul Fitri yang ditandai dengan titik berwarna ungu. Hal ini terjadi karena kecenderungan masyarakat melakukan penarikan uang untuk membeli kebutuhan dan persiapan perayaan Hari Raya Idul Fitri. Kenaikan *outflow* terjadi pada bulan-bulan berikut.

- Bulan November pada tahun 2003 dan 2004,
- Bulan Oktober pada tahun 2005, 2006 dan 2007,
- Bulan September pada tahun 2008, dan 2009,
- Bulan Agustus pada tahun 2010, 2011, dan 2012,
- Bulan Juli pada tahun 2013, 2014 dan 2015, dan
- Bulan Juni pada tahun 2016.

Rata-rata kenaikan *outflow* pada bulan saat terjadinya Hari Raya Idul Fitri dan satu bulan sebelumnya berdasarkan minggu



terjadinya Hari Raya Idul Fitri pada periode tahun 2003 hingga 2016 disajikan pada Gambar 4.27 berikut.



**Gambar 4.27** Rata-rata *Outflow* pada Saat dan Sebelum Hari Raya Idul Fitri

Kenaikan *outflow* pada bulan saat dan sebelum terjadinya Hari Raya Idul Fitri memiliki pola sebagai berikut.

- Apabila Idul Fitri terjadi pada minggu pertama, maka rata-rata *outflow* akan tinggi pada bulan sebelum terjadinya Hari Raya Idul Fitri. Rata-rata *outflow* sebelum Hari Raya Idul Fitri di Jawa Timur adalah sebesar 10.720,46 miliar rupiah, lalu mengalami penurunan rata-rata *outflow* menjadi 1.840,33 miliar rupiah pada bulan saat terjadinya Hari Raya Idul Fitri.
- Apabila Idul Fitri terjadi pada minggu kedua maka rata-rata *outflow* pada saat dan sebelum terjadinya Idul Fitri hampir sama. Rata-rata *outflow* sebelum Idul Fitri sebesar 5.285,32 miliar rupiah dan sebesar 4.137,07 miliar rupiah pada saat Hari Raya Idul Fitri.
- Apabila Idul Fitri terjadi pada minggu ketiga, rata-rata *outflow* bulan saat Hari Raya Idul Fitri menjadi tinggi dibanding sebelum Hari Raya Idul Fitri. Tercatat nilai rata-rata *outflow* pada bulan terjadinya Hari Raya Idul Fitri sebesar 8.803,908 miliar rupiah, sedangkan pada bulan

sebelum Hari Raya Idul Fitri, rata-rata *outflow* bernilai sebesar 4.883,01 miliar rupiah.

- d. Apabila Idul Fitri terjadi pada minggu keempat, rata-rata *outflow* bulan saat Hari Raya Idul Fitri lebih tinggi dibanding satu bulan sebelum Hari Raya Idul Fitri. Nilai rata-rata *outflow* pada bulan terjadinya Hari Raya Idul Fitri tercatat sebesar 8.667,14 miliar rupiah, sedangkan pada bulan sebelum Hari Raya Idul Fitri, rata-rata *outflow* tercatat sebesar 3.671,11 miliar rupiah.


Uang kartal terdiri dari uang kertas dan logam. Berikut disajikan statistika deskriptif *inflow* dan *outflow* uang kertas untuk masing-masing pecahan.

**Tabel 4.22** Statistika Deskriptif *Inflow* dan *Outflow* per pecahan (Miliar Rupiah)

Variabel	Pecahan	Rata-rata	Standar Deviasi	Minimum	Maksimum
<i>Inflow</i>	100.000	1819	1454	327	9289
	50.000	1569,5	783,6	374,5	4904
	20.000	112,08	62,19	19,12	326,26
	10.000	73,56	47,08	17,67	346,17
	5.000	57,38	41,33	11,81	305,49
	2.000	28,76	22,6	0,26	98,67
	1.000	12,317	10,295	1,167	50,455
<i>Outflow</i>	100.000	1697	1419	160	10028
	50.000	1336	881,5	109,6	5295,7
	20.000	94,76	110,54	2,32	882,29
	10.000	67,22	99,34	3,14	712,63
	5.000	56,7	105,24	2,71	818,87
	2.000	33,52	76,51	1,06	361,02
	1.000	8,682	12,922	0,123	100,968

Tabel 4.22 merupakan statistika deskriptif *inflow* dan *outflow* uang kertas per pecahan dari tahun 2003 hingga 2016. Pecahan uang Rp2.000,00 baru beredar pada Agustus 2009. Rata-rata *inflow* pecahan Rp100.000,00 sebesar 1.819 miliar rupiah dengan standar deviasi 1.454 miliar rupiah, sedangkan rata-rata *outflow* pecahan Rp100.000,00 tercatat sebesar 1.697 miliar rupiah


dengan standar deviasi sebesar 1.419 miliar rupiah. Statistika deskriptif untuk pecahan lain dapat dilihat pada Tabel 4.22.




**Gambar 4.28** Pola Kenaikan *Inflow* dan *Outflow* di Jawa Timur Per Pecahan

Apabila diperhatikan nilai *inflow* dan *outflow* pada tiap pecahan uang kertas yang beredar di masyarakat seperti Gambar 4.28, pecahan Rp100.000,00 dan Rp50.000,00 mendominasi jumlah *inflow* dan *outflow* total karena memiliki nilai yang sangat besar dibanding pecahan yang lain. Pada nilai *inflow* dan *outflow* pecahan Rp100.000,00 dan Rp50.000,00 nampak adanya efek pada pola data yang disebabkan oleh beberapa kebijakan yang dilakukan oleh Bank Indonesia seperti yang telah dijelaskan sebelumnya.

Berikut disajikan *time series plot* untuk data *inflow* per pecahan uang kertas di Jawa Timur pada periode tahun 2003 hingga tahun 2016.




**Gambar 4.29** *Time Series Plot* Data *Inflow* di Jawa Timur Per Pecahan



**Gambar 4.29** *Time Series Plot* Data Inflow di Jawa Timur Per Pecahan  
(lanjutan)


Berdasarkan Gambar 4.29, ditunjukkan bahwa pada waktu-waktu tertentu terjadi kenaikan *inflow* yang terjadi diakibatkan oleh Hari Raya Idul Fitri. Oleh karena itu dapat dikatakan bahwa *inflow* uang kertas per pecahan di Jawa Timur dipengaruhi oleh faktor variasi kalender. Selain dari *time series plot*, dapat juga menggunakan *boxplot* untuk melihat apakah ada pola musiman pada masing-masing pecahan uang kertas.




**Gambar 4.30** Boxplot Bulanan Data *Inflow* di Jawa Timur Per Pecahan

Pada Gambar 4.30, garis merah menunjukkan garis yang menghubungkan nilai rata-rata *outflow* pada tiap-tiap bulan, sedangkan garis biru menghubungkan nilai median *outflow* pada tiap-tiap bulan pada periode waktu yang diamati. Pada pecahan Rp100.000,00 hingga Rp2.000,00, varians data pada bulan Januari,

Agustus, September, Oktober dan November cenderung lebih besar dibanding bulan-bulan lainnya, yang disebabkan oleh efek variasi kalender. Dari Gambar 4.30, ditunjukkan bahwa nilai rata-rata dan median pada pecahan Rp100.000,00, Rp10.000,00, Rp5.000,00 dan Rp2.000,00 di bulan terjadinya Hari Raya Idul Fitri maupun satu bulan setelahnya memiliki selisih yang besar, yang mengindikasikan adanya suatu data yang bernilai cukup berbeda dibanding data yang lain (*outlier*) yang diindikasikan disebabkan oleh efek variasi kalender. Untuk efek musiman, rata-rata *inflow* tertinggi terjadi pada bulan Januari. *Inflow* yang tinggi pada bulan Januari ini diduga karena efek perayaan Natal dan Tahun Baru pada bulan sebelumnya, dimana masyarakat cenderung menyetorkan uangnya setelah melakukan perayaan-perayaan tersebut. Berikut disajikan *time series plot* dari data *inflow* uang kertas id Jawa Timur per pecahan pada periode Januari 2003 hingga Desember 2016.




**Gambar 4.31** Time Series Plot Data Outflow per Pecahan




**Gambar 4.31** Time Series Plot Data Outflow per Pecahan (lanjutan)

Sama halnya dengan *inflow*, pada data *outflow* per pecahan uang kertas di Jawa Timur pada periode tahun 2003 hingga 2016, nampak bahwa adanya efek variasi kalender Hari Raya Idul Fitri dan efek musiman yang menyebabkan peningkatan nilai *outflow* pada tiap pecahan tersebut seperti yang ditunjukkan pada Gambar 4.31. Selain *Time Series plot*, berikut disajikan pula *boxplot* untuk *outflow* per pecahan uang kertas di Jawa Timur.



**Gambar 4.32** Boxplot Bulanan Data Outflow di Jawa Timur Per Pecahan



**Gambar 4.32** Boxplot Bulanan Data *Outflow* di Jawa Timur Per Pecahan (lanjutan)

Gambar 4.32 menunjukkan rata-rata *outflow* uang kertas pada masing-masing pecahan. Rata-rata tertinggi *outflow* uang kertas pecahan Rp100.000,00 dan Rp50.000,00 terjadi pada bulan Desember dan terendah terjadi pada bulan Januari. Rata-rata *outflow* pecahan Rp20.000,00, Rp10.000,00 dan Rp5.000,00 tertinggi terjadi pada bulan Juni, sedangkan untuk pecahan Rp2.000,00 terjadi pada bulan Juli, dan untuk pecahan Rp1.000,00 terjadi pada bulan Oktober.



### 4.3 Pemodelan *Inflow* dan *Outflow* Uang Kartal di Jawa Timur Menggunakan *Time Series Regression*

Pada Pembahasan 4.2 mengenai karakteristik data *inflow* dan *outflow*, diketahui bahwa *inflow* dan *outflow* dipengaruhi oleh kejadian Hari Raya Idul Fitri. Variabel *dummy* yang digunakan untuk analisis menggunakan *Time Series regression* (TSR) antara lain variabel *dummy* tren, musiman dan variasi kalender dapat dilihat pada Tabel 3.2. Minggu terjadinya Hari Raya Idul Fitri juga memegang peranan terhadap nilai permintaan uang di masyarakat, serta memberikan pola yang berbeda terhadap *inflow* dan *outflow* uang kartal di Jawa Timur.

Tahapan pertama yang dilakukan pada pemodelan regresi *Time Series* adalah pengujian asumsi residual yang meliputi *white noise* dan distribusi normal untuk *outflow* uang kertas per pecahan di Jawa Timur.

**Tabel 4.23** Hasil Pengujian Asumsi Residual Model Regresi *Time Series*

Model TSR	Uji <i>White Noise</i>				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i> Rp100,000,00	6	13,40	6	0,037	<0,0100
	12	42,69	12	0,000	
	18	57,17	18	0,000	
	24	69,93	24	0,000	
	30	76,61	30	0,000	
<i>Outflow</i> Rp50,000,00	6	4,20	6	0,650	>0,1500
	12	17,60	12	0,128	
	18	30,64	18	0,032	
	24	41,29	24	0,016	
	30	54,37	30	0,004	
<i>Outflow</i> Rp20,000,00	6	2,45	6	0,875	<0,0100
	12	8,13	12	0,775	
	18	14,60	18	0,689	
	24	21,35	24	0,618	
	30	22,89	30	0,820	
<i>Outflow</i> Rp10,000,00	6	5,00	6	0,543	<0,0100
	12	8,91	12	0,711	
	18	10,45	18	0,916	
	24	12,38	24	0,975	
	30	13,84	30	0,995	

**Tabel 4.23** Hasil Pengujian Asumsi Residual Model Regresi *Time Series* (lanjutan)

Model TSR	Uji <i>White Noise</i>				Uji Normalitas
	Hingga Lag ke	Chi- Squared	DF	P-Value	P-value
<i>Outflow</i> Rp5,000,00	6	5,42	6	0,491	<0,0100
	12	13,29	12	0,349	
	18	17,94	18	0,460	
	24	36,16	24	0,053	
	30	39,76	30	0,110	
<i>Outflow</i> Rp2,000,00	6	2,25	6	0,896	<0,0100
	12	7,03	12	0,856	
	18	8,38	18	0,972	
	24	11,54	24	0,985	
<i>Outflow</i> Rp1,000,00	6	24,96	6	0,000	<0,0100
	12	59,12	12	0,000	
	18	68,13	18	0,000	
	24	81,92	24	0,000	
	30	84,48	30	0,000	
<i>Inflow</i> Rp100,000,00	6	8,97	6	0,175	<0,0100
	12	19,74	12	0,072	
	18	23,94	18	0,157	
	24	29,97	24	0,186	
	30	32,26	30	0,356	
<i>Inflow</i> Rp50,000,00	6	3,02	6	0,807	<0,0100
	12	9,14	12	0,691	
	18	15,54	18	0,625	
	24	24,08	24	0,457	
	30	33,35	30	0,308	
<i>Inflow</i> Rp20,000,00	6	17,62	6	0,007	<0,0100
	12	49,58	12	0,000	
	18	59,88	18	0,000	
	24	81,73	24	0,000	
	30	98,39	30	0,000	
<i>Inflow</i> Rp10,000,00	6	22,48	6	0,001	<0,0100
	12	78,01	12	0,000	
	18	90,30	18	0,000	
	24	114,58	24	0,000	
	30	128,55	30	0,000	

**Tabel 4.23** Hasil Pengujian Asumsi Residual Model Regresi *Time Series* (lanjutan)

Model TSR	Uji <i>White Noise</i>				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Inflow</i> Rp5,000,00	6	66,41	6	0,000	<0,0100
	12	177,61	12	0,000	
	18	212,25	18	0,000	
	24	263,89	24	0,000	
	30	292,20	30	0,000	
<i>Inflow</i> Rp2,000,00	6	11,90	6	0,064	>0,1500
	12	22,24	12	0,035	
	18	33,79	18	0,013	
	24	42,75	24	0,011	
<i>Inflow</i> Rp1,000,00	6	48,39	6	0,000	>0,1500
	12	136,40	12	0,000	
	18	172,88	18	0,000	
	24	217,36	24	0,000	
	30	242,62	30	0,000	

Berdasarkan uji Ljung-Box yang ditunjukkan pada Tabel 4.23, *p-value* residual model regresi *Time Series* pada *outflow* pecahan Rp20.000,00, Rp10.000,00, Rp5.000,00 dan Rp2.000 bernilai lebih dari  $\alpha$  (0,05) yang berarti sudah memenuhi asumsi *white noise*, sedangkan *outflow* pada pecahan Rp100.000,00, Rp50.000,00 dan Rp1.000,00 *p-value* bernilai kurang dari  $\alpha$  (0,05). Berbeda dengan *inflow* dimana pecahan Rp100.000,00 dan Rp50.000,00 menghasilkan *p-value* lebih dari  $\alpha$  (0,05). Pada *inflow* dan *outflow* pecahan-pecahan yang tidak *white noise* tersebut kemudian dimasukkan lag-lag yang signifikan sebagai variabel prediktor.

Pengidentifikasian lag yang signifikan menggunakan plot ACF dan PACF dari residual model. Pada plot ACF menunjukkan pola turun cepat yang berarti data telah stasioner dalam *mean*, dan pada plot PACF nampak lag 1, 10 dan 12 yang signifikan. Lag-lag inilah yang kemudian ditambahkan menjadi variabel prediktor pada regresi *time series*. Setelah ditambahkan lag tersebut, kemudian dilakukan pengujian asumsi residual kembali.

**Tabel 4.24** Hasil Pengujian Asumsi Residual Model Regresi *Time Series* *Outflow* Pecahan Rp100.000 setelah ditambah Lag

Model TSR	Uji <i>White Noise</i>				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i> Rp100.000.00	6	2,16	6	0,9048	0,1139
	12	4,53	12	0,9720	
	18	13,86	18	0,7384	
	24	19,47	24	0,7266	

Pada Tabel 4.24, ditunjukkan bahwa setelah ditambah lag-lag yang signifikan sebagai variabel prediktor, residual model TSR dari *outflow* pecahan Rp100.000,00 memenuhi asumsi *white noise* dan berdistribusi normal, ditunjukkan dengan nilai *p-value* uji Ljung-Box dan Kolmogorov-Smirnov yang lebih dari  $\alpha$  (0,05). Langkah selanjutnya adalah melakukan estimasi dan pengujian signifikansi parameter.

**Tabel 4.25** Hasil Pengujian Signifikansi Parameter Model *Time Series* *Regression Data Outflow* pecahan Rp100.000,00

Variabel	Koefisien	Std. Error	t-value	P-value
<i>t</i>	16,780	8,388	2,00	0,048
<i>D</i> <sub>2,t</sub>	-919,764	479,988	-1,92	0,058
<i>D</i> <sub>3,t</sub>	-2851,900	658,517	-4,33	0,000
<i>tD</i> <sub>2,t</sub>	-4,345	10,036	-0,43	0,666
<i>tD</i> <sub>3,t</sub>	17,501	9,455	1,85	0,067
<i>M</i> <sub>1,t</sub>	394,565	297,976	1,32	0,188
<i>M</i> <sub>2,t</sub>	160,917	295,526	0,54	0,587
<i>M</i> <sub>3,t</sub>	497,355	305,457	1,63	0,106
<i>M</i> <sub>4,t</sub>	736,304	308,960	2,38	0,019
<i>M</i> <sub>5,t</sub>	711,272	318,639	2,23	0,028
<i>M</i> <sub>6,t</sub>	997,691	328,183	3,04	0,003
<i>M</i> <sub>7,t</sub>	1347,100	335,325	4,02	0,000
<i>M</i> <sub>8,t</sub>	735,935	335,562	2,19	0,030
<i>M</i> <sub>9,t</sub>	607,598	321,160	1,89	0,061

**Tabel 4.25** Hasil Pengujian Signifikansi Parameter Model *Time Series Regression* Data *Outflow* pecahan Rp100.000,00

Variabel	Koefisien	Std. Error	t-value	P-value
$M_{10,t}$	438,786	335,898	1,31	0,194
$M_{11,t}$	360,575	317,007	1,14	0,258
$M_{12,t}$	1132,400	348,428	3,25	0,002
$V_{1,t}$	322,711	383,045	0,84	0,401
$V_{2,t}$	428,656	294,630	1,45	0,148
$V_{3,t}$	948,949	447,135	2,12	0,036
$V_{4,t}$	2326,900	349,241	6,66	0,000
$V_{1,t-1}$	1946,400	376,651	5,17	0,000
$V_{2,t-1}$	864,759	270,826	3,19	0,002
$V_{3,t-1}$	-76,665	317,574	-0,24	0,810
$V_{4,t-1}$	-122,845	305,254	-0,40	0,688
$Y_{1,t-1}$	-0,239	0,055	-4,32	0,000
$Y_{1,t-10}$	-0,145	0,060	-2,42	0,017
$Y_{1,t-12}$	0,422	0,090	4,67	0,000

Pada pengujian signifikansi parameter untuk data *outflow* pecahan Rp100.000,00 di Jawa Timur yang disajikan pada Tabel 4.25, diperoleh hasil bahwa terdapat beberapa variabel yang tidak signifikan yaitu yang menghasilkan *p-value* lebih dari  $\alpha$  (0,05). Selanjutnya perlu dilakukan seleksi variabel menggunakan *Backward Elimination*. Hasil pengujian signifikansi parameter menggunakan *Backward Elimination* disajikan pada Tabel 4.26.

**Tabel 4.26** Hasil Pengujian Signifikansi Parameter Model Regresi *Time Series Outflow* Pecahan Rp100.000 Menggunakan *Backward Elimination*

Variabel	Koefisien	Std. Error	t-value	P-value
$t$	21,734	2,831	7,68	0,000
$D_{2,t}$	-1322,500	181,026	-7,31	0,000
$D_{3,t}$	-1298,500	287,523	-4,52	0,000

**Tabel 4.26** Hasil Pengujian Signifikansi Parameter Model Regresi *Time Series Outflow* Pecahan Rp100.000 Menggunakan *Backward Elimination*

Variabel	Koefisien	Std. Error	t-value	P-value
$M_{6,t}$	337,685	154,012	2,19	0,030
$M_{7,t}$	668,760	157,854	4,24	0,000
$M_{12,t}$	427,426	164,384	2,60	0,010
$V_{4,t}$	1969,400	306,354	6,43	0,000
$V_{1,t-1}$	1810,000	357,729	5,06	0,000
$V_{2,t-1}$	849,188	255,486	3,32	0,001
$Y_{1,t-1}$	-0,182	0,044	-4,17	0,000
$Y_{1,t-10}$	-0,095	0,046	-2,04	0,044
$Y_{1,t-12}$	0,648	0,051	12,66	0,000

Setelah mendapatkan parameter yang signifikan, dilakukan pengujian asumsi residual kembali untuk memastikan residual sudah memenuhi asumsi *white noise* dan distribusi normal. Pengujian tersebut dapat dilihat pada Tabel 4.27 berikut.


**Tabel 4.27** Hasil Pengujian Asumsi Residual Model Regresi *Time Series Outflow* Pecahan Rp100.000 setelah Seleksi Variabel

Pecahan	Uji <i>White Noise</i>				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i> Rp100.00000	6	4,78	6	0,572	0,019
	12	6,70	12	0,877	
	18	15,13	18	0,653	
	24	20,03	24	0,695	

Tabel 4.27 menunjukkan bahwa pada pengujian Ljung-Box dan Kolmogorov-Smirnov model sudah memenuhi asumsi *white noise*, tetapi belum memenuhi asumsi residual berdistribusi normal. Menurut Kostenko dan Hyndman (2008), uji signifikansi


dan asumsi dapat diabaikan dalam kepentingan peramalan, hal yang lebih penting adalah kemampuan model dalam melakukan peramalan, pernyataan tersebut diperkuat oleh Armstrong (2007).

Setelah melakukan pengujian signifikansi parameter dan uji asumsi, tahap selanjutnya adalah melakukan peramalan data *out-sample* untuk mengetahui kinerja model. Berikut adalah plot antara data actual *out-sample outflow* pecahan Rp100.000 pada tahun 2016 dengan nilai ramalannya menggunakan *time series regression*.



**Gambar 4.33** Plot Data Aktual dan Ramalan *Outflow* Pecahan Rp100.000,00 pada Data *Out-Sample* Menggunakan Model TSR

Dari Gambar 4.33, ditunjukkan bahwa data pada bulan Mei, Juni dan Juli (bulan 5,6, dan 7) masih berada di luar interval. Hal ini mengindikasikan bahwa model masih kurang dapat menangkap efek variasi kalender yang terjadi pada Juli 2016 (bulan 7). Kenaikan *outflow* pada bulan-bulan ini sangat besar dibanding kenaikan *outflow* pada tahun-tahun sebelumnya yang disebabkan oleh variasi kalender, atau dapat dikatakan data *outflow* pecahan Rp100.000 pada tahun 2016 memiliki varians yang besar. Maka untuk mengantisipasi hal ini, dilakukan pula pemodelan menggunakan regresi *time series* pada data *outflow* yang dilakukan uji stasioneritas varians terlebih dahulu.



**Gambar 4.34** Box-Cox Data *Outflow* pecahan Rp100.000,00

Nilai lamda pada Box-Cox Transformation adalah sebesar 0, dimana pada batas atas dan batas bawahnya tidak mengandung nilai 1 yang mengindikasikan data tidak stasioner dalam varians. Dari hasil inilah maka dilakukan transformasi pada data. Dilakukan tahapan yang sama seperti sebelumnya, yaitu pengujian asumsi residual dan estimasi parameter. Hasil pengujian asumsi residual menggunakan TSR pada data *outflow* Rp100.000,00 yang telah ditransformasi disajikan pada Tabel 4.28 berikut.

**Tabel 4.28** Hasil Pengujian Asumsi Residual Model Regresi *Time Series* Transformasi *Outflow* Pecahan Rp100.000

Pecahan	Uji White Noise				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i> Rp100.00000	6	4,04	6	0,671	>0,1500
	12	15,08	12	0,237	
	18	28,04	18	0,061	
	24	31,79	24	0,132	
	30	36,39	30	0,196	

Pada Tabel 4.28 ditunjukkan bahwa pada pengujian asumsi *white noise* dengan Ljung-Box, *p-value* lebih dari  $\alpha$  (0,05) yang berarti residual telah memenuhi asumsi *white noise*. Pada uji normalitas menggunakan Kolmogorov-Smirnov, *p-value* yang



dihasilkan bernilai lebih dari  $\alpha$  (0,05) yang berarti residual berdistribusi normal. Selanjutnya adalah melakukan estimasi dan uji signifikansi parameter. Apabila ada variabel yang tidak signifikan maka dilakukan seleksi variabel menggunakan *Backward Elimination*.

**Tabel 4.29** Hasil Pengujian Signifikansi Parameter Model Regresi *Time Series* Transformasi *Outflow* Pecahan Rp100.000 Menggunakan *Backward Elimination*


Variabel	Koefisien	Std. Error	t-value	P-value
$t$	0,008	0,002	3,51	0,001
$D_{2,t}$	-0,996	0,131	-7,59	0,000
$D_{3,t}$	-1,383	0,311	-4,45	0,000
$tD_{3,t}$	0,007	0,003	2,23	0,028
$M_{1,t}$	6,036	0,108	55,91	0,000
$M_{2,t}$	6,440	0,109	59,28	0,000
$M_{3,t}$	6,874	0,109	62,88	0,000
$M_{4,t}$	6,929	0,110	62,98	0,000
$M_{5,t}$	6,870	0,111	62,03	0,000
$M_{6,t}$	7,234	0,112	64,87	0,000
$M_{7,t}$	7,015	0,115	61,24	0,000
$M_{8,t}$	6,888	0,116	59,20	0,000
$M_{9,t}$	6,912	0,118	58,65	0,000
$M_{10,t}$	6,766	0,121	55,74	0,000
$M_{11,t}$	6,748	0,119	56,62	0,000
$M_{12,t}$	7,404	0,116	63,57	0,000
$V_{1,t}$	-0,624	0,235	-2,66	0,009
$V_{2,t}$	0,466	0,167	2,80	0,006
$V_{3,t}$	0,964	0,192	5,02	0,000
$V_{4,t}$	0,902	0,167	5,40	0,000
$V_{1,t-1}$	1,237	0,235	5,26	0,000
$V_{2,t-1}$	0,733	0,167	4,40	0,000

Setelah didapatkan koefisien parameter model TSR yang signifikan maka selanjutnya adalah menguji asumsi residual dari model TSR yang telah dilakukan seleksi variabel.

**Tabel 4.30** Hasil Pengujian Asumsi Residual Model Regresi *Time Series* Transformasi *Outflow* Pecahan Rp100.000 setelah Signifikansi Parameter

Pecahan	Uji White Noise				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i> Rp100.000.00	6	3,92	6	0,688	>0,1500
	12	14,83	12	0,251	
	18	28,60	18	0,054	
	24	32,62	24	0,112	
	30	37,81	30	0,155	

Tabel 4.30 menunjukkan setelah dilakukan transformasi pada data *outflow* pecahan Rp100.000,00, residual model TSR yang telah dilakukan seleksi variabel juga memenuhi asumsi residual *white noise* dan distribusi normal. Hal ini menunjukkan bahwa setelah dilakukan transformasi yang bertujuan untuk menstabilkan varians data, pola variasi kalender pada bulan Juni (bulan 6) dapat ditangkap oleh prediksi interval dari model. Jumlah data *out-sample* yang keluar dari interval ramalan juga lebih sedikit. Interval ramalan yang dihasilkan cenderung lebih sempit dibanding yang dihasilkan model TSR tanpa transformasi, kecuali pada bulan ke-6. Berikut adalah hasil ramalan untuk *out-sample* data *outflow* Rp100.000,00.



**Gambar 4.35** Plot Data Aktual dan Ramalan *Outflow* Pecahan Rp100.000,00 pada data *out-sample* Menggunakan Model TSR dengan Transformasi

Langkah yang sama dilakukan untuk *inflow* dan *outflow* pecahan yang lain. Pada data *outflow* pecahan Rp100.000,00, Rp50.000,00, Rp2.000,00 dan Rp1.000,00 serta pada data *inflow* pecahan Rp100.000,00, Rp50.000,00, Rp20.000,00, Rp10.000,00, dan Rp1.000,00 dilakukan transformasi guna menghasilkan hasil yang lebih baik, sedangkan untuk pecahan yang tidak disebutkan tidak dilakukan transformasi data. Berikut adalah hasil pengujian asumsi residual pada model TSR *inflow* dan *outflow* per pecahan.

**Tabel 4.31** Hasil Pengujian Asumsi Residual Model Regresi *Time Series* Data *Inflow* dan *Outflow* setelah Signifikansi Parameter

Pecahan	Uji White Noise				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i> Rp100,000,00	6	3,92	6	0,688	>0,1500
	12	14,83	12	0,251	
	18	28,60	18	0,054	
	24	32,62	24	0,112	
<i>Outflow</i> Rp50,000,00	6	8,28	6	0,218	0,0824
	12	13,72	12	0,319	
	18	26,27	18	0,094	
	24	29,30	24	0,209	
<i>Outflow</i> Rp20,000,00	6	2,74	6	0,841	<0,0100
	12	8,11	12	0,776	
	18	14,15	18	0,719	
	24	19,54	24	0,723	
<i>Outflow</i> Rp10,000,00	6	2,19	6	0,901	<0,0100
	12	5,04	12	0,956	
	18	6,90	18	0,998	
	24	8,86	24	0,999	
<i>Outflow</i> Rp5,000,00	6	5,92	6	0,432	<0,0100
	12	7,68	12	0,810	
	18	10,18	18	0,926	
	24	21,98	24	0,581	

**Tabel 4.31** Hasil Pengujian Asumsi Residual Model Regresi *Time Series* Data *Inflow* dan *Outflow* setelah Signifikansi Parameter (lanjutan)

Pecahan	Uji <i>White Noise</i>				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i> Rp2,000,00	6	6,53	6	0,366	>0,1500
	12	10,79	12	0,547	
	18	11,60	18	0,867	
	24	17,61	24	0,822	
<i>Outflow</i> Rp1,000,00	6	9,70	6	0,138	>0,1500
	12	12,16	12	0,433	
	18	20,02	18	0,332	
	24	29,50	24	0,202	
<i>Inflow</i> Rp100,000,00	6	3,36	6	0,762	<0,0100
	12	5,83	12	0,924	
	18	12,89	18	0,798	
	24	20,24	24	0,683	
<i>Inflow</i> Rp50,000,00	6	5,78	6	0,448	>0,1500
	12	10,14	12	0,603	
	18	12,68	18	0,810	
	24	19,44	24	0,728	
<i>Inflow</i> Rp20,000,00	6	10,10	6	0,121	0,0801
	12	14,50	12	0,270	
	18	21,10	18	0,274	
	24	34,16	24	0,082	
<i>Inflow</i> Rp10,000,00	6	11,16	6	0,084	>0,1500
	12	14,97	12	0,243	
	18	16,77	18	0,539	
	24	25,17	24	0,396	
<i>Inflow</i> Rp5,000,00	6	2,89	6	0,823	0,0227
	12	18,36	12	0,105	
	18	22,73	18	0,201	
	24	31,37	24	0,144	


**Tabel 4.31** Hasil Pengujian Asumsi Residual Model Regresi *Time Series* Data *Inflow* dan *Outflow* setelah Signifikansi Parameter (lanjutan)

Pecahan	Uji White Noise				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Inflow</i> Rp2,000,00	6	2,50	6	0,868	>0,1500
	12	3,98	12	0,984	
	18	9,18	18	0,956	
	24	15,39	24	0,909	
<i>Inflow</i> Rp1,000,00	6	9,24	6	0,161	>0,1500
	12	15,16	12	0,233	
	18	20,65	18	0,298	
	24	25,63	24	0,372	

Yang perlu dilakukan pada langkah selanjutnya adalah menulis persamaan matematis pada tiap model TSR. Berikut adalah model TSR *outflow* pecahan Rp100.000,00 di Jawa Timur.


$$\ln(Y_{1,t}) = 0,153t - 0,996D_{2,t} - 1,383D_{3,t} + 0,007tD_{3,t} + 6,036M_{1,t} + 6,439M_{2,t} + 6,874M_{3,t} + 6,929M_{4,t} + 6,869M_{5,t} + 7,234M_{6,t} + 7,015M_{7,t} + 6,888M_{8,t} + 6,912M_{9,t} + 6,766M_{10,t} + 6,748M_{11,t} + 7,404M_{12,t} - 0,624V_{1,t} + 0,466V_{2,t} + 0,964V_{3,t} + 0,9025V_{4,t} + 1,237V_{1,t-1} + 0,733V_{2,t-1} + a_t$$

Dengan cara yang sama dilakukan pada data *outflow* dan *inflow* pecahan yang lain. Koefisien parameter yang signifikan pada model TSR data *inflow* dan *outflow* pecahan yang lain dapat dilihat pada Lampiran. Selisih antara data aktual dengan data hasil ramalan *inflow* dan *outflow* uang kertas per pecahan untuk *out-sample* disajikan pada Gambar 4.36.



**Gambar 4.36** Perbandingan Model TSR Data Aktual dengan nilai Ramalan *out-sample* Data Outflow Per Pecahan

Gambar 4.36 menunjukkan nilai ramalan *out-sample* data *outflow* per pecahan dari masing-masing model *time series regression* terbaik yang diperoleh. Visualisasi nilai ramalan *out-sample* data *inflow* per pecahan menggunakan model *time series regression* disajikan pada Gambar 4.37 berikut.



**Gambar 4.37** Perbandingan Model TSR Data Aktual dengan nilai Ramalan *out-sample* Data Inflow Per Pecahan

Berdasarkan Gambar 4.36 dan Gambar 4.37 nampak bahwa pada data ramalan *out-sample* menggunakan metode *time series regression* hasilnya sudah cukup baik. Pada beberapa pecahan uang, ramalan interval yang dihasilkan mampu menangkap

kejadian variasi kalender, namun paa beberapa pecahaan yang lain belum. Selanjutnya adalah menghitung nilai kesalahan ramalan data *out-sample* menggunakan kriteria RMSE, MAE dan MdAE pada tiap pecahan *inflow* dan *outflow*.

**Tabel 4.32** Nilai Kesalahan Ramalan Model *Time Series Regression*


Data	Pecahan	RMSE	MAE	MdAE	Ramalan Keluar Interval	Keterangan
<i>Outflow</i>	Rp100,000	1624,520	876,420	284,718	0/12	WN – DN
	Rp50,000	1169,910	563,854	156,395	0/12	WN – DN
	Rp20,000	184,308	87,581	16,249	3/12	WN – TDN
	Rp10,000	196,617	78,483	10,999	2/12	WN – TDN
	Rp5,000	74,518	43,000	25,224	2/12	WN – TDN
	Rp2,000	95,407	33,795	2,116	2/12	WN – DN
	Rp1,000	1,274	0,577	0,206	3/12	WN – DN
<i>Inflow</i>	Rp100,000	751,639	634,186	642,735	0/12	WN – TDN
	Rp50,000	556,384	381,372	238,859	0/12	WN – DN
	Rp20,000	48,084	26,424	18,321	1/12	WN – DN
	Rp10,000	37,195	26,286	13,623	0/12	WN – DN
	Rp5,000	33,409	19,776	9,100	3/12	WN – TDN
	Rp2,000	14,819	12,958	12,173	2/12	WN – DN
	Rp1,000	1,004	0,875	0,821	4/12	WN - TDN

Nilai kebaikan model TSR berdasarkan kriteria RMSE, MAE dan MdAE diperoleh RMSE untuk *outflow* pecahan Rp100.000,00 sebesar 1.624,520 miliar rupiah, dengan nilai MAE sebesar 876,420 miliar rupiah dan nilai MdAE sebesar 284,718 miliar rupiah. Perbedaan yang cukup besar antara MAE dan MdAE menunjukkan adanya suatu data *outflow* pada bulan tertentu yang nilainya jauh lebih tinggi yaitu yang terjadi pada bulan Juli 2016 karena adanya efek Hari Raya Idul Fitri. Hal ini menunjukkan apabila terdapat nilai *outlier* dapat menyebabkan nilai rata-rata *error* menjadi terpengaruh. Oleh karena itulah digunakan kriteria median yang lebih *robust* terhadap data *outlier*.



4.4    **Pemodelan *Inflow* dan *Outflow* Uang Kartal di Jawa Timur Menggunakan ARIMAX (ARIMA dengan Variasi Kalender)**

Pemodelan ARIMA dengan tambahan efek variasi kalender disebut dengan model ARIMAX atau model ARIMA dengan variabel eksogen. Model ini menggunakan variabel *dummy* sama seperti model regresi *Time Series* pada subbab sebelumnya. Langkah awal pemodelan ARIMA dengan efek variasi kalender ini adalah mengidentifikasi model berdasarkan plot ACF dan PACF. Berikut adalah plot ACF dan PACF dari residual model *time series regression* (TSR) *outflow* pecahan Rp100.000,00.



**Gambar 4.38** Plot ACF dan PACF Residual Model TSR *Outflow* pecahan Rp100.000,00

Berdasarkan plot ACF dan PACF tersebut, didapatkan dugaan model untuk ARIMA dengan efek variasi kalender untuk data *outflow* pecahan Rp100.000,00. Model dugaan tersebut kemudian digunakan untuk melakukan pengujian asumsi residual yang meliputi uji *white noise* dan distribusi normal.

**Tabel 4.33** Hasil Pengujian Asumsi Residual Model ARIMAX Data *Outflow* pecahan Rp100.0000,00

Pecahan	Uji <i>White Noise</i>			Uji Normalitas	
	Hingga Lag ke	Chi-Squared	DF	<i>P-Value</i>	<i>P-value</i>
<i>Outflow</i> Rp100,000,00	6	5,56	4	0,2349	0,0155
	12	9,53	10	0,4830	
	18	20,62	16	0,1937	
	24	25,74	22	0,2632	
	30	33,66	28	0,2124	

Dapat dilihat pada Tabel 4.33 bahwa residual model ARIMAX pada data *outflow* pecahan Rp100.000,00 sudah memenuhi asumsi *white noise*, namun tidak memenuhi asumsi distribusi normal. Hal ini bisa disebabkan oleh adanya *outlier* efek variasi kalender pada bulan-bulan tertentu. Setelah didapatkan model yang memenuhi asumsi *white noise* maka tahapan selanjutnya adalah melakukan estimasi dan pengujian signifikansi parameter. Hasil pengujian signifikansi parameter model variasi kalender pada data *outflow* pecahan uang kertas Rp100.000,000 di Jawa Timur setelah dilakukan eliminasi menggunakan metode *Backward Elimination* disajikan pada Tabel 4.34 berikut.

**Tabel 4.34** Hasil Pengujian Signifikansi Parameter Model ARIMAX *Outflow* Pecahan Rp100.000 Menggunakan *Backward Elimination*

Variabel	Parameter	Koefisien	Standar Error	t-value	P-value
-	$\hat{\theta}_{12}$	-0,54	0,09	-6,33	0,000
-	$\hat{\phi}_5$	0,21	0,09	2,35	0,020
-	$\hat{\phi}_{10}$	-0,25	0,09	-2,71	0,008
$D_{3,t}$	$\hat{\beta}_3$	-3544,80	656,81	-5,40	0,000
$tD_{3,t}$	$\hat{\beta}_5$	37,52	5,19	7,23	0,000
$M_{1,t}$	$\hat{\gamma}_1$	236,28	236,17	1,00	0,319
$M_{3,t}$	$\hat{\gamma}_3$	761,76	234,36	3,25	0,002
$M_{4,t}$	$\hat{\gamma}_4$	985,31	233,18	4,23	0,000
$M_{5,t}$	$\hat{\gamma}_5$	881,98	235,51	3,74	0,000
$M_{6,t}$	$\hat{\gamma}_6$	1265,60	235,77	5,37	0,000
$M_{7,t}$	$\hat{\gamma}_7$	1570,20	241,73	6,50	0,000
$M_{8,t}$	$\hat{\gamma}_8$	953,15	244,36	3,90	0,000
$M_{9,t}$	$\hat{\gamma}_9$	832,70	240,83	3,46	0,001
$M_{10,t}$	$\hat{\gamma}_{10}$	483,74	242,63	1,99	0,048

**Tabel 4.34** Hasil Pengujian Signifikansi Parameter Model ARIMAX *Outflow* Pecahan Rp100.000 Menggunakan *Backward Elimination* (lanjutan)

Variabel	Parameter	Koefisien	Standar Error	t-value	P-value
$M_{11,t}$	$\hat{\gamma}_{11}$	364,79	242,83	1,50	0,135
$M_{12,t}$	$\hat{\gamma}_{12}$	1915,10	237,41	8,07	0,000
$V_{2,t}$	$\hat{\delta}_2$	1387,30	266,19	5,21	0,000
$V_{3,t}$	$\hat{\delta}_3$	1859,60	346,63	5,36	0,000
$V_{4,t}$	$\hat{\delta}_4$	2634,20	291,55	9,04	0,000
$V_{1,t-1}$	$\hat{\omega}_1$	2437,70	385,54	6,32	0,000
$V_{2,t-1}$	$\hat{\omega}_2$	582,28	263,23	2,21	0,029


Berdasarkan uji signifikansi parameter menggunakan metode *Backward Elimination* pada model variasi kalender diperoleh parameter yang signifikan dengan *p-value* kurang dari  $\alpha$  (0,05). Setelah mengetahui parameter yang signifikan, kemudian melakukan pengujian asumsi residual kembali untuk mengetahui apakah model memenuhi asumsi residual yaitu *white noise* dan berdistribusi normal yang dapat dilihat pada Tabel 4.35 berikut.

**Tabel 4.35** Hasil Pengujian Asumsi Residual Model Variasi Kalender Data *Outflow* pecahan Rp100.000,00 setelah Pengujian Signifikansi Parameter

Pecahan	Uji <i>White Noise</i>			Uji Normalitas	
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i>	6	4,44	3	0,217	>0,1500
Rp100.000,00	12	9,16	9	0,423	
	18	17,21	15	0,307	
	24	27,60	21	0,152	
	30	33,91	27	0,169	

Tabel 4.35 menunjukkan bahwa pada pengujian Ljung-Box dan Kolmogorov-Smirnov model sudah memenuhi asumsi *white noise* dan berdistribusi normal. Tahap selanjutnya adalah melakukan peramalan data *out-sample* untuk mengetahui kinerja model. Berikut adalah plot antara data aktual *out-sample outflow*

pecahan Rp100.000 pada tahun 2016 dengan nilai ramalannya menggunakan ARIMAX.



**Gambar 4.39** Plot Data Aktual dan Ramalan *Outflow* Pecahan Rp100.000,00 pada data *out-sample* Menggunakan Model ARIMAX

Dari Gambar 4.39, ditunjukkan bahwa data pada bulan Mei, Juni dan Juli (bulan 5,6, dan 7) masih berada di luar ramalan interval. Hal ini mengindikasikan bahwa model masih kurang dapat menangkap efek variasi kalender yang terjadi pada Juli 2016 (bulan 7). Hal ini menunjukkan nilai kenaikan *outflow* pecahan Rp100.000 pada tahun 2016 memiliki varians yang besar. dilakukan pula pemodelan menggunakan ARIMAX dengan data *outflow* pecahan Rp100.000 yang ditransformasi terlebih dahulu.

**Tabel 4.36** Hasil Pengujian Asumsi Residual Model ARIMAX Transformasi *Outflow* Pecahan Rp100.000

Pecahan	Uji White Noise				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i> Rp100.00000	6	4,64	5	0,461	>0,1500
	12	11,59	11	0,395	
	18	26,96	17	0,059	
	24	32,06	23	0,099	
	30	38,38	29	0,114	

Pada Tabel 4.36 ditunjukkan bahwa pada pengujian asumsi *white noise* dengan Ljung-Box, *p-value* lebih dari  $\alpha$  (0,05) yang berarti residual telah memenuhi asumsi *white noise*. Pada uji normalitas menggunakan Kolmogorov-Smirnov, *p-value* yang

dihasilkan bernilai lebih dari  $\alpha$  (0,05) yang berarti residual berdistribusi normal. Selanjutnya adalah melakukan estimasi dan uji signifikansi parameter. Apabila ada variabel yang tidak signifikan maka dilakukan seleksi variabel menggunakan *Backward Elimination*.

**Tabel 4.37** Hasil Pengujian Signifikansi Parameter Model ARIMAX Transformasi *Outflow* Pecahan Rp100.000 Menggunakan *Backward Elimination*

Variabel	Parameter	Koefisien	Standar Error	<i>t-value</i>	<i>P-value</i>
-	$\hat{\theta}_{13}$	0,274	0,087	3,17	0,002
<i>t</i>	$\hat{\beta}_1$	0,008	0,002	3,25	0,001
<i>D</i> <sub>2</sub>	$\hat{\beta}_2$	-0,950	0,130	-7,3	0,000
<i>D</i> <sub>3</sub>	$\hat{\beta}_3$	-1,352	0,273	-4,95	0,000
<i>tD</i> <sub>3</sub>	$\hat{\beta}_5$	0,008	0,003	2,59	0,011
<i>M</i> <sub>1,<i>t</i></sub>	$\hat{\gamma}_1$	6,038	0,104	58,2	0,000
<i>M</i> <sub>2,<i>t</i></sub>	$\hat{\gamma}_2$	6,450	0,105	61,62	0,000
<i>M</i> <sub>3,<i>t</i></sub>	$\hat{\gamma}_3$	6,878	0,105	65,34	0,000
<i>M</i> <sub>4,<i>t</i></sub>	$\hat{\gamma}_4$	6,937	0,106	65,38	0,000
<i>M</i> <sub>5,<i>t</i></sub>	$\hat{\gamma}_5$	6,875	0,107	64,45	0,000
<i>M</i> <sub>6,<i>t</i></sub>	$\hat{\gamma}_6$	7,241	0,108	67,35	0,000
<i>M</i> <sub>7,<i>t</i></sub>	$\hat{\gamma}_7$	7,030	0,111	63,48	0,000
<i>M</i> <sub>8,<i>t</i></sub>	$\hat{\gamma}_8$	6,923	0,112	61,56	0,000
<i>M</i> <sub>9,<i>t</i></sub>	$\hat{\gamma}_9$	6,938	0,114	60,61	0,000
<i>M</i> <sub>10,<i>t</i></sub>	$\hat{\gamma}_{10}$	6,798	0,117	58,09	0,000
<i>M</i> <sub>11,<i>t</i></sub>	$\hat{\gamma}_{11}$	6,768	0,115	58,71	0,000
<i>M</i> <sub>12,<i>t</i></sub>	$\hat{\gamma}_{12}$	7,380	0,113	65,36	0,000

**Tabel 4.37** Hasil Pengujian Signifikansi Parameter Model ARIMAX Transformasi *Outflow* Pecahan Rp100.000 Menggunakan *Backward Elimination* (lanjutan)

Variabel	Parameter	Koefisien	Standar Error	t-value	P-value
$V_{1,t}$	$\hat{\delta}_1$	-0,614	0,229	-2,69	0,008
$V_{2,t}$	$\hat{\delta}_2$	0,460	0,163	2,82	0,006
$V_{3,t}$	$\hat{\delta}_3$	0,897	0,187	4,79	0,000
$V_{4,t}$	$\hat{\delta}_4$	0,803	0,160	5,01	0,000
$V_{1,t-1}$	$\hat{\omega}_1$	1,229	0,229	5,38	0,000
$V_{2,t-1}$	$\hat{\omega}_2$	0,622	0,164	3,79	0,000


Setelah didapatkan koefisien parameter model ARIMAX yang signifikan maka selanjutnya adalah menguji asumsi residual dari model TSR yang telah dilakukan seleksi variabel.

**Tabel 4.38** Hasil Pengujian Asumsi Residual Model ARIMAX Transformasi *Outflow* Pecahan Rp100.000 setelah Signifikansi Parameter

Pecahan	Uji <i>White Noise</i>				Uji Normalitas
	Hingga Lag ke	Chi-Squared	DF	P-Value	P-value
<i>Outflow</i> Rp100.000.00	6	4,47	5	0,4838	>0,1500
	12	18,14	11	0,0785	
	18	25,81	17	0,0781	
	24	32,15	23	0,097	
	30	36,81	29	0,1511	

Tabel 4.38 menunjukkan setelah dilakukan transformasi pada data *outflow* pecahan Rp100.000,00, residual model ARIMAX yang telah dilakukan seleksi variabel juga memenuhi asumsi residual *white noise* dan distribusi normal. Hal ini menunjukkan bahwa setelah dilakukan transformasi, pola variasi kalender pada bulan Juni (bulan 6) dapat ditangkap oleh prediksi interval dari model. Jumlah data *out-sample* yang keluar dari interval ramalan juga lebih sedikit serta interval ramalan yang dihasilkan cenderung lebih sempit dibanding yang dihasilkan

model ARIMAX tanpa transformasi. Berikut adalah hasil ramalan untuk *out-sample* data *outflow* Rp100.000,00.




**Gambar 4.40** Plot Data Aktual dan Ramalan *Outflow* Pecahan Rp100.000,00 pada data *out-sample* Menggunakan Model ARIMAX dengan Transformasi

Langkah yang sama dilakukan untuk *inflow* dan *outflow* pecahan yang lain, dan hasilnya dapat dilihat pada Lampiran. Pada data *outflow* semua pecahan kecuali pecahan Rp5.000,00 serta pada data *inflow* pecahan Rp100.000,00, Rp50.000,00, dan Rp20.000,00 dilakukan transformasi guna menghasilkan hasil yang lebih baik. Sedangkan untuk pecahan yang tidak disebutkan tidak dilakukan transformasi data.

Yang perlu dilakukan pada langkah selanjutnya adalah menulis persamaan matematis pada tiap model ARIMAX. Berikut adalah model ARIMAX *outflow* pecahan Rp100.000,00 di Jawa Timur.


$$\ln(Y_{1,t}) = 0,274 t + 0,008 D_{2,t} - 0,950 D_{3,t} - 1,352 t D_{3,t} + 0,008 M_{1,t} + 6,038 M_{2,t} + 6,450 M_{3,t} + 6,937 M_{4,t} + 6,875 M_{5,t} + 7,241 M_{6,t} + 7,030 M_{7,t} + 6,923 M_{8,t} + 6,938 M_{9,t} + 6,798 M_{10,t} + 6,768 M_{11,t} + 7,380 M_{12,t} - 0,614 V_{1,t} + 0,460 V_{2,t} + 0,897 V_{3,t} + 0,803 V_{4,t} + 1,229 V_{1,t-1} + 0,622 V_{2,t-1} + a_{1,t} + 0,274 a_{1,t-13}$$

Koefisien parameter yang signifikan pada model ARIMAX data *inflow* dan *outflow* pecahan yang lain dapat dilihat pada Lampiran. Perbandingan antara data aktual dengan data hasil ramalan *inflow* dan *outflow* uang kertas di Jawa Timur per pecahan berdasarkan *out-sample* menggunakan model ARIMAX disajikan pada Gambar 4.41.



**Gambar 4.41** Perbandingan Model ARIMAX Data Aktual dengan nilai Ramalan *out-sample* Data *Outflow* Per Pecahan





**Gambar 4.42** Perbandingan Model ARIMAX Data Aktual dengan nilai Ramalan *out-sample* Data *Inflow* Per Pecahan

Berdasarkan Gambar 4.41 dan Gambar 4.42 nampak bahwa pada peramalan data *out-sample* menggunakan metode ARIMAX menghasilkan nilai ramalan yang cukup baik. Pada beberapa

pecahan uang, ramalan interval yang dihasilkan mampu menangkap kejadian variasi kalender, namun paa beberapa pecahaan yang lain belum. Selanjutnya adalah menghitung nilai kesalahan ramalan data *out-sample* menggunakan kriteria RMSE, MAE dan MdAE pada tiap pecahan *inflow* dan *outflow*.

**Tabel 4.39** Nilai Kesalahan Ramalan Model ARIMAX

Data	Pecahan	RMSE	MAE	MdAE	Ramalan	Keterangan
					Keluar Interval	
<i>Outflow</i>	Rp100.000	1.830,52	956,42	317,16	0/12	WN – DN
	Rp50.000	1.120,10	578,08	262,04	0/12	WN – DN
	Rp20.000	147,64	66,83	15,617	1/12	WN – DN
	Rp10.000	112,27	47,36	6,450	2/12	WN – DN
	Rp5.000	119,71	59,29	21,128	2/12	WN – TDN
	Rp2.000	104,78	38,38	2,031	2/12	WN – DN
	Rp1.000	0,96	0,53	0,281	5/12	WN – DN
<i>Inflow</i>	Rp100.000	636,21	456,37	274,53	0/12	WN – TDN
	Rp50.000	365,18	271,12	217,65	0/12	WN – TDN
	Rp20.000	60,64	41,05	25,885	4/12	WN – DN
	Rp10.000	41,59	23,88	11,790	1/12	WN – TDN
	Rp5.000	47,79	37,96	32,250	3/12	WN – TDN
	Rp2.000	23,59	17,58	7,965	2/12	WN – DN
	Rp1.000	8,69	8,50	8,764	0/12	WN - TDN

Nilai kebaikan model ARIMAX berdasarkan kriteria RMSE, MAE dan MdAE diperoleh RMSE untuk *outflow* pecahan Rp100.000,00 sebesar 1.830,52 miliar rupiah, dengan nilai MAE sebesar 956,417 miliar rupiah dan nilai MdAE sebesar 317,16 miliar rupiah.

#### 4.5 Pemodelan *Inflow* dan *Outflow* Uang Kartal di Jawa Timur Menggunakan ARIMAX-Quantile Regression (ARIMAX-QR)


Pada pemodelan menggunakan metode ARIMAX-Quantile Regression terdapat beberapa pendekatan yang digunakan.

Pendekatan pertama adalah menggunakan metode ARIMAX-QR seperti yang dilakukan oleh Arunraj & Ahrens (2015) yaitu melakukan pemodelan regresi kuantil antara data *inflow* dan *outflow* per pecahan dengan menggunakan variabel *dummy* tren, musiman dan variasi kalender serta prediksi data *inflow* dan *outflow* menggunakan ARIMA sebagai variabel prediktornya. Pendekatan kedua adalah menggunakan pemodelan ARIMAX-QR dengan menggabungkan nilai ramalan menggunakan *Time Series regression* data *inflow* dan *outflow* dengan nilai prediksi residual menggunakan model *quantile regression* dengan variabel prediktor antara lain lag-lag dari residual itu tersebut serta prediksi data *inflow* dan *outflow* menggunakan ARIMA.

#### 4.5.1 ARIMAX-Quantile Regression Model 1

Tahapan pertama yang harus dilakukan pada penelitian ini adalah melakukan pemodelan ARIMA terhadap data *inflow* dan *outflow* per pecahan uang kertas. Pemodelan ARIMA menggunakan prosedur Box-Jenkins yang meliputi identifikasi model, estimasi parameter, cek diagnosa dan melakukan peramalan.


Berdasarkan Gambar 4.34 menunjukkan bahwa berdasarkan uji Box-Cox, data *outflow* pecahan Rp100.0000,00 tidak stasioner dalam varians sehingga perlu dilakukan transformasi.



**Gambar 4.43** Plot ACF Dan PACF Data *Outflow* Pecahan Rp100.000,00 Setelah Transformasi

Pada plot ACF yang ditunjukkan pada Gambar 4.43 menunjukkan pola yang turun lambat, dimana hal ini mengindikasikan data belum stasioner terhadap *mean*. Pada plot ACF dan PACF nampak pada lag ke 12 dan 24 tinggi yang menunjukkan

adanya pola musiman (dengan periode 12) sehingga perlu dilakukan *differencing*. Berikut adalah plot ACF dan PACF *outflow* pecahan Rp100.000,00 setelah dilakukan *differencing* non-musiman.



**Gambar 4.44** Plot ACF dan PACF Data *Outflow* Pecahan Rp100.000,00 Setelah Transformasi dan Differencing

Setelah dilakukan transformasi dan *differencing* terlihat bahwa plot ACF sudah stasioner karena menunjukkan pola *dies down* dan plot PACF menunjukkan pola *cut off* setelah lag 2, maka *outflow* uang kertas pecahan Rp100.000,00 stasioner dalam varians dan *mean*. Setelah data memenuhi asumsi stasioner dalam varians dan *mean*, langkah selanjutnya adalah menentukan orde  $p$  dan  $q$  untuk menduga model ARIMA. Proses identifikasi model ARIMA untuk data *inflow* dan *outflow* pecahan uang kertas yang lain dapat dilihat pada Lampiran. Dugaan model ARIMA untuk semua data disajikan pada Tabel 4.40.

**Tabel 4.40** Model ARIMA Data *Inflow* dan *Outflow* Per Pecahan

Data	Pecahan	Dugaan Model ARIMA
<i>Outflow</i>	Rp100.000	$(2,1,[13])(1,0,0)^{12}$
	Rp50.000	$(0,1,1)(1,0,0)^{12}$
	Rp20.000	$(1,0,[13])(1,0,0)^{12}$
	Rp10.000	$(1,0,[11,23])(1,0,0)^{12}$
	Rp5.000	$(1,0,0)(1,0,0)^{12}$
	Rp2.000	$(1,0,[11,12,23])$
	Rp1.000	$([1,23],0,[12])$

**Tabel 4.40** Model ARIMA Data *Inflow* dan *Outflow* Per Pecahan (lanjutan)

Data	Pecahan	Dugaan Model ARIMA
<i>Inflow</i>	Rp100.000	$(6,1,[23])(0,0,1)^{12}$
	Rp50.000	$(2,1,0)(1,0,0)^{12}$
	Rp20.000	$(0,1,[1,23])(1,0,0)^{12}$
	Rp10.000	$(1,0,[11])(1,0,0)^{12}$
	Rp5.000	$([1,11],0,[23])(0,0,1)^{12}$
	Rp2.000	$(1,0,[23])(0,0,1)^{12}$
	Rp1.000	$(1,1,[11,23])(1,0,0)^{12}$

Dari masing-masing model di tiap pecahan uang kertas, langkah selanjutnya adalah melakukan estimasi dan pengujian signifikansi parameter.

**Tabel 4.41** Uji Signifikansi Parameter Model ARIMA Data *Outflow* Pecahan Rp100.000,00 di Jawa Timur

Parameter	Koefisien	Std.Error	t-value	P-value
$\theta_{13}$	0,3526	0,0804	4,39	0,0000
$\phi_1$	-0,6971	0,0736	-9,47	0,0000
$\phi_2$	-0,4433	0,0738	-6,01	0,0000
$\Phi_1$	0,7212	0,0613	11,77	0,0000

Setelah didapatkan parameter koefisien yang signifikan maka selanjutnya perlu dilakukan pengujian asumsi residual yang meliputi uji *white noise* dan uji normalitas.

**Tabel 4.42** Uji Asumsi *White Noise* dan Distribusi Normal Residual ARIMA Data *Outflow* pecahan Rp100.000,00

Model ARIMA	Uji Asumsi <i>White Noise</i>				Uji Normalitas
	Hingga Lag ke	Chi-square	DF	P-Value	P-value
<i>Outflow</i> Rp100.000 $(2,1,[13])(1,0,0)^{12}$	6	5,23	2	0,0732	0,0115
	12	11,9	8	0,1556	
	18	15,24	14	0,3620	
	24	23,34	20	0,2724	
	30	28,98	26	0,3121	

Berdasarkan Tabel 4.42, ditunjukkan bahwa pada uji Ljung-Box,  $p$ -value pada lag-lagnya bernilai lebih dari alfa (0,05), hal ini berarti residual model TSR telah *white noise*. Pada pengujian distribusi normal pada residual menggunakan Kolmogorov-Smirnov, residual tidak memenuhi asumsi distribusi normal.

Setelah mendapatkan model ARIMA pada tiap pecahan *inflow* dan *outflow* uang kertas di Jawa Timur maka langkah selanjutnya adalah melakukan peramalan untuk data *in-sample* dan *out-sample* pada masing-masing data. Setelah nilai ramalan model ARIMA pada masing-masing data diperoleh, tahap selanjutnya adalah melakukan pemodelan regresi kuantil antara data *inflow* dan *outflow* per pecahan dengan variabel *dummy* dan nilai ramalan model ARIMA per pecahan.

**Tabel 4.43** Estimasi Koefisien Regresi Kuantil Data *Outflow* Pecahan Rp100.000,00

Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$t$	5,268	0,000	5,052	0,210	11,154	0,000
$D_2$	-283,659	0,005	-347,073	0,252	-750,721	0,000
$D_3$	-331,595	0,012	-1189,73	0,004	-4095,15	0,000
$tD_2$	-4,010	0,027	-2,373	0,667	-0,953	0,751
$tD_3$	-0,435	0,784	8,513	0,083	30,703	0,000
$M_{1,t}$	-40,190	0,418	201,457	0,187	254,538	0,003
$M_{2,t}$	125,755	0,009	161,757	0,267	552,864	0,000
$M_{3,t}$	489,746	0,000	503,791	0,001	701,269	0,000
$M_{4,t}$	332,145	0,000	646,682	0,000	971,833	0,000
$M_{5,t}$	418,609	0,000	623,115	0,000	760,406	0,000
$M_{6,t}$	577,927	0,000	803,783	0,000	1519,184	0,000
$M_{7,t}$	489,960	0,000	666,288	0,000	912,796	0,000
$M_{8,t}$	-143,934	0,006	542,783	0,001	1439,130	0,000
$M_{9,t}$	-220,847	0,000	500,021	0,002	547,406	0,000
$M_{10,t}$	543,189	0,000	320,195	0,051	643,528	0,000
$M_{11,t}$	402,503	0,000	344,933	0,029	591,621	0,000

**Tabel 4.43** Estimasi Koefisien Regresi Kuantil Data *Outflow* Pecahan Rp100.000,00 (lanjutan)


Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$M_{12,t}$	486,334	0,000	1328,096	0,000	1497,118	0,000
$V_{1,t}$	-386,051	0,000	-287,953	0,287	-696,451	0,000
$V_{2,t}$	21,109	0,745	340,997	0,089	40,621	0,709
$V_{3,t}$	1845,858	0,000	1031,397	0,000	861,960	0,000
$V_{4,t}$	682,263	0,000	607,901	0,003	4056,018	0,000
$V_{1,t-1}$	1842,883	0,000	1897,319	0,000	1794,717	0,000
$V_{2,t-1}$	501,802	0,000	886,689	0,000	1886,571	0,000
$V_{3,t-1}$	719,713	0,000	128,854	0,559	-363,091	0,003
$V_{4,t-1}$	158,446	0,012	288,130	0,134	363,784	0,001
$\hat{z}_{1,t}$	0,324	0,000	0,428	0,000	0,389	0,000

Tabel 4.43 menunjukkan nilai estimasi koefisien regresi kuantil pada kuantil 0,025, 0,50 dan 0,975 beserta hasil uji signifikansi parameternya. Nilai prediksi untuk kuantil 0,025 akan menjadi batas ramalan interval bawah dan untuk kuantil 0,975 akan menjadi batas ramalan interval atas. Nilai prediksi untuk  $\tau = 0,50$  merupakan nilai ramalan berdasarkan kriteria median yang kemudian akan menjadi nilai ramalan titik dari model ARIMAX-QR. Model ARIMAX-QR yang terbentuk untuk kuantil 0,50 adalah sebagai berikut.

$$\begin{aligned} \hat{Y}_{1,t}(0,50) = & 5,29 t - 283,66 D_{2,t} - 331,59 D_{3,t} - 4,01 t D_{2,t} - 0,43 t D_{3,t} - \\ & 40,19 M_{1,t} + 125,75 M_{2,t} + 489,75 M_{3,t} + 332,145 M_{4,t} + \\ & 418,61 M_{5,t} + 577,93 M_{6,t} + 489,96 M_{7,t} - 143,93 M_{8,t} - \\ & 220,85 M_{9,t} + 543,19 M_{10,t} + 402,50 M_{11,t} + 486,33 M_{12,t} - \\ & 386,05 V_{1,t} + 21,11 V_{2,t} + 1845,86 V_{3,t} + 682,26 V_{4,t} + 1842,88 V_{1,t-1} + \\ & 501,80 V_{2,t-1} + 719,71 V_{3,t-1} + 158,45 V_{3,t-1} + 0,32 \hat{Z}_{1,t} \end{aligned}$$


Dari model regresi pada tiap kuantil kemudian dilakukan peramalan untuk pada data *outflow* pecahan Rp100.000,00. Dengan cara yang sama dengan pemodelan ARIMAX-QR model

1 *outflow* pecahan Rp100.000,00, dilakukan pemodelan menggunakan ARIMAX-QR model 1 pada data *inflow* dan *outflow* pecahan yang lain. Nilai ramalan data *out-sample* pada data *outflow* per pecahan uang kertas disajikan pada Gambar 4.45 berikut.



**Gambar 4.45** Perbandingan Model ARIMAX-QR Model 1 Data Aktual dengan nilai Ramalan *out-sample* Data *Outflow* Per Pecahan





**Gambar 4. 46** Perbandingan Model ARIMAX-QR Model 1 Data Aktual dengan nilai Ramalan *out-sample* Data *Inflow* Per Pecahan

Berdasarkan Gambar 4.45, nampak bahwa pada *outflow* pecahan Rp100.000,00 dan Rp50.000 nilai ramalan (merah) mampu mengikuti fluktuasi data aktual *out-sample* (hitam) serta ramalan interval yang dihasilkan mampu menangkap kejadian yang disebabkan oleh variasi kalender, dimana Hari Raya Idul Fitri pada tahun 2016 terjadi pada bulan Juli (bulan 7). Pada pecahan-pecahan lainnya, hasil ramalan menggunakan ARIMAX-QR ini belum dapat menangkap pola variasi kalender, namun dapat menghasilkan ramalan interval yang lebih sempit dibanding metode *Time Series regression* dan ARIMAX. Plot antara data ramalan dan data aktual untuk data *inflow* menggunakan metode ARIMAX-QR Model 1 dapat dilihat di Gambar 4.46.

Langkah selanjutnya adalah menghitung nilai kesalahan ramalan *out-sample* pada data *inflow* dan *outflow* per pecahan. Tabel 4.44 menyajikan nilai kesalahan ramalan *out-sample* pada data *inflow* dan *outflow* per pecahan menggunakan metode ARIMAX-QR Model 1.

**Tabel 4.44** Nilai Kesalahan Ramalan Model ARIMAX-QR Model 1

Data	Pecahan	RMSE	MAE	MdAE	Out
<i>Outflow</i>	Rp100,000	1.567,508	1.075,759	668,319	3/12
	Rp50,000	555,976	417,231	359,411	1/12
	Rp20,000	180,805	83,410	16,784	3/12
	Rp10,000	149,930	63,846	17,462	3/12
	Rp5,000	195,916	78,437	6,186	5/12
	Rp2,000	65,090	25,065	2,185	5/12*
	Rp1,000	9,478	3,490	0,304	3/12*
<i>Inflow</i>	Rp100,000	1.461,059	932,236	537,157	7/12
	Rp50,000	292,886	243,480	202,678	9/12*
	Rp20,000	55,410	34,342	18,537	2/12
	Rp10,000	88,480	49,952	21,038	3/12*
	Rp5,000	34,060	23,312	13,543	3/12
	Rp2,000	17,922	13,414	8,363	6/12*
	Rp1,000	1,307	1,000	0,774	3/12*

**Keterangan:** I = Independen , H = Homogen , DN = Berdistribusi Normal

TI = Tidak Independen, TH = Tidak Homogen, TDN = Tidak Normal

\* = terdapat hasil ramalan yang *overlap* antar kuantil

Nilai RMSE ramalan *out-sample* pada data *outflow* pecahan Rp100.000,00 sebesar 1.567,51 miliar rupiah, dengan nilai AME sebesar 1.075,76 miliar rupiah dan MdAE sebesar 668,32 miliar rupiah seperti yang ditunjukkan pada Tabel 4.44. Selisih nilai MAE dan MdAE yang cukup besar ini yaitu sebesar 407,44 miliar diduga terjadi karena adanya nilai *outflow* yang cukup besar yang terjadi pada bulan Juni (bulan 6) yang disebabkan oleh Hari Raya Idul Fitri.

#### 4.5.2 ARIMAX-Quantile Regression Model 2

Pada ARIMAX-QR model 2, tahap pertama yang dilakukan adalah melakukan pemodelan data menggunakan metode ARIMAX seperti pada subbab 4.4. Setelah didapatkan model ARIMAX terbaik pada masing-masing data kemudian dilakukan peramalan data *in-sample* dan *out-sample* menggunakan metode ARIMAX ( $\hat{Z}_t^*$ ). Langkah selanjutnya yang dilakukan adalah melakukan regresi kuantil pada data dengan prediktornya yaitu nilai prediksi ARIMAX yang didapatkan sebelumnya. Berikut adalah nilai estimasi koefisien parameter model *quantile regression* dari data *outflow* pecahan Rp100.00,00.

**Tabel 4.45** Nilai Estimasi Koefisien Parameter ARIMAX-QR Model 2


Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$\hat{Z}_{1,t}^*$	0,515	0,000	0,972	0,010	1,608	0,000

Dapat dilihat pada Tabel 4.45, nilai estimasi koefisien regresi kuantil pada  $\tau = 0,025$ ,  $0,50$  dan  $0,975$  beserta hasil uji signifikansi parameternya pada ARIMAX-QR model 2 untuk data *outflow* pecahan Rp100.000,00. Dari hasil yang diperoleh ini maka untuk  $\tau = 0,50$  model yang terbentuk adalah sebagai berikut.


$$Y_{1,t} = 0,972\hat{Z}_{1,t}^* + \varepsilon_t.$$

Dengan cara yang sama dilakukan pemodelan pada data *outflow* dan *outflow* pecahan yang lain. Dari model regresi pada tiap kuantil

di tiap data inilah kemudian dilakukan peramalan untuk data *out-sample*.



**Gambar 4.47** Perbandingan Model 2 ARIMAX-QR Data Aktual dengan Nilai Ramalan *out-sample* Data *Outflow* Per Pecahan



**Gambar 4.48** Perbandingan Model 2 ARIMAX-QR Data Aktual dengan Nilai Ramalan *out-sample* Data Inflow Per Pecahan

Pada Gambar 4.47 dan 4.48 diperlihatkan bahwa nilai ramalan titik pada data *out-sample* menggunakan ARIMAX-QR

model 2 mampu menangkap pola variasi kalender. Pada pecahan besar seperti pada *inflow* Rp100.000,00 dan Rp50.000,00, nilai ramalan titik (kuantil 0,50) cenderung *overestimate*, sedangkan pada pecahan Rp20.000,00, Rp10.000,00, Rp5.000,00 dan Rp2.000,00 baik pada *inflow* dan *outflow* nilai ramalan yang dihasilkan cenderung *underestimated*. Hasil ramalan interval yang dihasilkan yaitu nilai ramalan pada kuantil 0,025 dan 0,975 juga mampu mengikuti pola dari data. Selanjutnya dari hasil ramalan yang didapatkan ini kemudian dilakukan evaluasi model berdasarkan nilai kesalahan ramalan.

**Tabel 4.46** Nilai Kesalahan Ramalan Model ARIMAX-QR Model 2

Data	Pecahan	RMSE	MAE	MdAE	Out
<i>Outflow</i>	Rp100.000	1548,61	976,53	472,26	1/12
	Rp50.000	510,28	368,86	285,36	1/12
	Rp20.000	149,70	67,50	15,79	4/12
	Rp10.000	119,86	49,89	7,99	1/12
	Rp5.000	135,50	62,38	19,51	1/12
	Rp2.000	106,35	40,58	4,95	1/12*
	Rp1.000	1,01	0,58	0,35	5/12
<i>Inflow</i>	Rp100.000	752,22	510,13	346,04	0/12
	Rp50.000	391,66	267,95	211,71	0/12
	Rp20.000	60,11	40,67	25,31	4/12
	Rp10.000	41,29	23,78	11,71	1/12
	Rp5.000	39,641	21,377	10,786	2/12
	Rp2.000	32,96	19,68	8,64	1/12
	Rp1.000	1,86	1,50	1,00	7/12
<b>Keterangan:</b> I = Independen , H = Homogen , DN = Berdistribusi Normal TI = Tidak Independen, TH =Tidak Homogen , TDN = Tidak Normal * = terdapat hasil ramalan yang <i>overlap</i> antar kuantil					

Tabel 4.46 menunjukkan bahwa nilai RMSE ramalan *out-sample* pada data *outflow* pecahan Rp100.000,00 sebesar 1.548,61 miliar rupiah, dengan nilai MAE dan MdAE masing-masing sebesar 976,53 miliar dan 472,26 miliar rupiah. Dari 14 pecahan, hanya terdapat 1 nilai ramalan yang *crossing* antar kuantilnya.

### 4.5.3 ARIMAX-Quantile Regression Model 3

Tahap pertama yang dilakukan pada metode ini adalah melakukan pemodelan *time series regression* (TSR) antara data

*inflow* dan *outflow* dengan variabel *dummy* sebagai variabel prediktor. Pada subbab 4.3 yang membahas pemodelan data *inflow* dan *outflow* menggunakan regresi *time series*, terdapat beberapa pecahan yang masih belum memenuhi asumsi *white noise* seperti yang ditunjukkan pada Tabel 4.23. Tahap kedua yang dilakukan pada metode ini adalah memodelkan nilai residual model TSR pada tahap pertama dengan lag-lagnya serta nilai ramalan ARIMA data *inflow* dan *outflow*. Model ARIMA yang digunakan disajikan pada Tabel 4.42. Metode ARIMAX-QR yang akan dibahas pada subbab ini akan menggunakan plot ACF dan PACF dari residual model TSR pada tahap pertama untuk mendeteksi lag-lag residual yang menjadi variabel prediktor pada pemodelan *quantile regression*.

Pada Gambar 4.32 ditunjukkan plot ACF dan PACF residual model TSR data *outflow* pecahan Rp100.000,00. Pada gambar tersebut, plot ACF sudah menunjukkan bahwa residual sudah stasioner, sehingga lag-lag yang signifikan pada PACF dapat digunakan untuk mendeteksi lag. Pada plot PACF, lag 1,10 dan 12 menunjukkan pola yang signifikan. Maka pada pemodelan *quantile regression* residual model TSR akan menggunakan lag-lagnya yaitu  $a_{1,t-1}$ ,  $a_{1,t-10}$  dan  $a_{1,t-12}$  serta nilai ramalan ARIMA data

*outflow* pecahan Rp100.000,00 ( $\hat{Z}_{1,t}$ ) sebagai variabel prediktornya.

Berikut adalah nilai estimasi koefisien model *quantile regression* dari residual model TSR data *outflow* pecahan Rp100.00,00.


**Tabel 4.47** Nilai Estimasi Koefisien Parameter ARIMAX-QR Model 3

Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$a_{1,t-1}$	-0,139	0,088	-0,215	0,000	-0,028	0,797
$a_{1,t-10}$	-0,083	0,316	-0,137	0,005	-0,113	0,314
$a_{1,t-12}$	0,535	0,000	0,363	0,000	0,292	0,014
$\hat{Z}_{1,t}$	-0,600	0,000	0,034	0,012	0,516	0,000

Dari hasil yang diperoleh maka model yang terbentuk untuk kuantil 0,50 untuk residual adalah sebagai berikut.


$$\hat{a}_{1,t}(0,50) = -0,22a_{t-1} - 0,14a_{t-10} + 0,36a_{t-12} + 0,03\hat{Z}_{1,t}.$$

Model ini kemudian digabungkan dengan model TSR yang telah dilakukan pada tahap 1. Dengan cara yang sama, dilakukan pada data *inflow* dan *outflow* pecahan data yang lain.



**Gambar 4.49** Perbandingan Model ARIMAX-QR Model 3 Data Aktual dengan nilai Ramalan *out-sample* Data *Outflow* Per Pecahan





**Gambar 4.50** Perbandingan Model ARIMAX-QR Model 3 Data Aktual dengan nilai Ramalan *out-sample* Data Inflow Per Pecahan

Berdasarkan Gambar 4.49, nilai ramalan *out-sample* pecahan Rp100.000,00 dan Rp50.000,00 mampu mengikuti pola

data aktualnya. Ramalan interval yang dihasilkan juga cukup baik. Sedangkan untuk pecahan yang bernilai lebih kecil, nilai ramalan masih kurang baik yaitu masih kurang dapat menangkap pola variasi kalender dari data aktual. Plot perbandingan ramalan *out-sample* data *inflow* per pecahan dapat dilihat pada Gambar 4.50. Kemudian dari hasil ramalan yang didapatkan ini kemudian dilakukan evaluasi model berdasarkan nilai kesalahan ramalan.

**Tabel 4.48** Nilai Kesalahan Ramalan Model ARIMAX-QR Model 3

Data	Pecahan	RMSE	MAE	MdAE	Out
<i>Outflow</i>	Rp100.000	1.403,449	1.008,119	661,999	2/12
	Rp50.000	418,528	328,423	288,152	0/12
	Rp20.000	177,421	88,230	25,755	7/12*
	Rp10.000	146,511	77,891	35,998	5/12
	Rp5.000	163,527	88,359	34,271	11/12
	Rp2.000	93,901	39,539	7,237	5/12*
	Rp1.000	9,533	5,878	2,000	12/12*
<i>Inflow</i>	Rp100.000	1.202,429	794,879	525,873	0/12
	Rp50.000	272,185	234,725	205,497	0/12
	Rp20.000	42,695	29,936	18,075	3/12*
	Rp10.000	39,929	22,575	10,977	3/12*
	Rp5.000	39,641	21,377	10,786	1/12*
	Rp2.000	14,847	11,026	7,555	3/12*
	Rp1.000	3,566	2,595	1,631	7/12*

**Keterangan:** I = Independen , H = Homogen , DN = Berdistribusi Normal

TI = Tidak Independen, TH =Tidak Homogen , TDN = Tidak Normal

\* = terdapat hasil ramalan yang *overlap* antar kuantil

Pada Tabel 4.48 ditunjukkan bahwa nilai RMSE ramalan *out-sample* pada data *outflow* pecahan Rp100.000,00 sebesar 1.403,45 miliar rupiah, dengan nilai MAE dan MdAE masing-masing sebesar 1.008,12 miliar dan 661,99 miliar rupiah. Dari 14 pecahan, terdapat 8 nilai ramalan yang *crossing* antar kuantilnya.

#### 4.5.4 ARIMAX-Quantile Regression Model 4

Pada pemodelan menggunakan ARIMAX-QR model ini, maka langkah pertama yang dilakukan adalah melakukan pemodelan *time series regression* yang kemudian dari model tersebut akan menghasilkan suatu nilai prediksi untuk data *in-sample* maupun *out-sample*. Selain nilai prediksi, dari model TSR ini juga akan menghasilkan suatu residual. Dari residual ini kemudian akan digunakan untuk mengidentifikasi lag  $Y_t$  menggunakan plot PACF residual. Pada plot PACF residual model TSR *outflow* Rp100.000,00 lag 1,10 dan 12 menunjukkan pola yang signifikan. Maka pada pemodelan *quantile regression* residual model TSR akan menggunakan lag-lagnya yaitu  $Y_{1,t-1}$ ,  $Y_{1,t-10}$  dan  $Y_{1,t-12}$ . Selanjutnya dilakukan pemodelan menggunakan regresi kuantil antara  $Y_t$  dengan prediktor meliputi nilai prediksi model TSR pada tahap 1 dan lag  $Y_t$ . Berikut adalah nilai estimasi koefisien parameter model *quantile regression* dari data *outflow* pecahan Rp100.00,00.


**Tabel 4.49** Nilai Esimasi Koefisien Parameter ARIMAX-QR Model 4

Variabel	$\tau = 0,025$		$\tau = 0,50$		$\tau = 0,975$	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
$Y_{1,t-1}$	-0,095	0,001	-0,041	0,361	-0,021	0,688
$Y_{1,t-10}$	-0,079	0,009	-0,099	0,042	0,067	0,235
$Y_{1,t-12}$	-0,017	0,725	0,281	0,001	0,886	0,000
$\hat{Y}_{1,t}^{(1)}$	0,687	0,000	0,874	0,000	0,726	0,000


Dapat dilihat pada Tabel 4.49, nilai estimasi koefisien regresi kuantil pada  $\tau = 0,025$ ,  $0,50$  dan  $0,975$  beserta hasil uji signifikansi parameternya pada ARIMAX-QR model 4 untuk data *outflow* pecahan Rp100.000,00. Dari hasil yang diperoleh maka model yang terbentuk untuk kuantil  $0,50$  adalah sebagai berikut.

$$\hat{Y}_{1,t}(0,50) = -0,04Y_{t-1} - 0,09Y_{t-10} + 0,281Y_{t-12} + 0,874\hat{Y}_{1,t}^{(1)}.$$

Dengan cara yang sama dilakukan pemodelan menggunakan ARIMAX-QR model 4 pada data *outflow* dan *outflow* pecahan yang lain. Dari model regresi pada tiap kuantil di tiap data inilah kemudian dilakukan peramalan untuk data *out-sample*. Berikut adalah plot nilai ramalan *out-sample* yang dihasilkan dari ARIMAX-QR model 4 pada data *outflow* dan *inflow* per pecahan uan kertas.



**Gambar 4.51** Perbandingan Model 4 ARIMAX-QR Data Aktual dengan Nilai Ramalan *out-sample* Data *Outflow* Per Pecahan



**Gambar 4.52** Perbandingan Model 4 ARIMAX-QR Data Aktual dengan Nilai Ramalan *out-sample* Data *Inflow* Per Pecahan

Berdasarkan Gambar 4.51 dan 4.52, nampak bahwa nilai ramalan yang dihasilkan oleh ARIMAX-QR model 4 cenderung *underestimate* dibanding data aktualnya, baik pada data *outflow* maupun data *inflow*. Pada gambar tersebut ditunjukkan pula bahwa metode ini mampu menangkap pola variasi kalender pada data serta menghasilkan nilai ramalan interval yakni menggunakan nilai ramalan pada kuantil 0,025 dan 0,975 dengan cukup baik. Selanjutnya adalah menghitung kebaikan model berdasarkan kesalahan ramalan yang dihasilkan dengan kriteria RMSE, MAE

dan MdAE. Hasil perhitungan nilai kesalahan ramalan *out-sample* data *outflow* dan *inflow* menggunakan ARIMAX-QR model 4 disajikan pada Tabel 4.50 berikut.

**Tabel 4.50** Nilai Kesalahan Ramalan Model ARIMAX-QR Model 4


Data	Pecahan	RMSE	MAE	MdAE	Out
<i>Outflow</i>	Rp100.000	1591,82	1100,00	643,48	1/12
	Rp50.000	473,27	379,71	326,24	0/12
	Rp20.000	182,15	90,11	20,46	5/12
	Rp10.000	150,94	77,07	31,14	4/12
	Rp5.000	174,75	86,07	25,44	4/12
	Rp2.000	96,33	38,41	6,43	2/12*
	Rp1.000	4,59	3,10	1,88	12/12*
<i>Inflow</i>	Rp100.000	1253,16	816,31	486,45	1/12
	Rp50.000	278,99	242,62	206,48	0/12
	Rp20.000	65,35	41,20	21,54	1/12
	Rp10.000	46,24	26,91	10,62	0/12
	Rp5.000	37,15	19,17	8,57	3/12
	Rp2.000	16,52	12,51	8,58	0/12
	Rp1.000	1,06	0,81	0,57	0/12
<b>Keterangan:</b> I = Independen , H = Homogen , DN = Berdistribusi Normal TI = Tidak Independen, TH =Tidak Homogen , TDN = Tidak Normal * = terdapat hasil ramalan yang <i>crossing</i> antar kuantil					

Dapat dilihat pada Tabel 4.50 bahwa nilai RMSE ramalan *out-sample* pada data *outflow* pecahan Rp100.000,00 sebesar 1.591,61 miliar rupiah, dengan nilai MAE dan MdAE masing-masing sebesar 1.100,00 miliar dan 643,48 miliar rupiah. Dari 14 pecahan, hanya terdapat 2 nilai ramalan yang *crossing* antar kuantilnya yaitu pada ramalan *out-sample* data *outflow* Rp2.000,00 dan Rp1.000,00.


#### 4.6 Perbandingan Keباikan Hasil Ramalan Data *Inflow* dan *Outflow* per Pecahan Menggunakan Metode *Time Series Regression*, ARIMAX dan ARIMAX-QR

Dari semua analisis yang telah dilakukan maka didapatkan model *time series regression*, ARIMAX, dan ARIMAX-QR untuk masing-masing data *inflow* dan *outflow* per pecahan. Dari model tersebut kemudian digunakan untuk meramalkan data *out-sample*

di tiap data. Berikut disajikan plot yang membandingkan nilai ramalan pada tiap metode pada tiap pecahan *inflow* dan *outflow*.



**Gambar 4.53** Perbandingan Hasil Ramalan *Out-sample* Tiap Metode pada Data *Outflow*



**Gambar 4.54** Perbandingan Hasil Ramalan *Out-sample* Tiap Metode pada Data *Inflow*

Gambar 4.53 dan Gambar 4.54 menyajikan perbandingan hasil ramalan *out-sample* dari tiap metode untuk data *outflow* dan *inflow*. Dari semua model tersebut, kemudian dilakukan perban-



dengan nilai kesalahan ramalan antar model di tiap data. Nilai kesalahan ramalan yang digunakan adalah RMSE, MAE dan MdAE. Model yang mempunyai nilai kesalahan ramalan lebih kecil dibanding model lainnya akan digunakan untuk meramalkan 12 periode ke depan (bulan Januari 2017 hingga Desember 2017). Perbandingan nilai kesalahan ramalan pada tiap metode di tiap data disajikan pada Tabel 4.51.

**Tabel 4.51** Perbandingan Nilai Kesalahan Ramalan *Out-sample* tiap Metode

Pecahan	Metode	RMSE	MAE	MdAE
<i>Outflow</i> Rp100,000	TSR	1624,52	876,42	284,72
	ARIMAX	1830,52	956,42	317,16
	ARIMAX-QR M.1	1567,51	1075,76	668,32
	ARIMAX-QR M.2	1548,61	976,53	472,26
	ARIMAX-QR M.3	1403,45	1008,12	662,00
	ARIMAX-QR M.4	1591,82	1100,00	643,48
<i>Outflow</i> Rp50,000	TSR	1169,91	563,85	156,40
	ARIMAX	1120,10	578,08	262,04
	ARIMAX-QR M.1	555,98	417,23	359,41
	ARIMAX-QR M.2	510,28	368,86	285,36
	ARIMAX-QR M.3	418,53	328,42	288,15
	ARIMAX-QR M.4	473,27	379,71	326,24
<i>Outflow</i> Rp20,000	TSR	184,31	87,58	16,25
	ARIMAX	147,64	66,83	15,62
	ARIMAX-QR M.1	180,81	83,41	16,78
	ARIMAX-QR M.2	149,70	67,50	15,79
	ARIMAX-QR M.3	177,42	88,23	25,76
	ARIMAX-QR M.4	182,15	90,11	20,46
<i>Outflow</i> Rp10,000	TSR	196,62	78,62	10,99
	ARIMAX	112,27	47,36	6,45
	ARIMAX-QR M.1	149,93	63,85	17,46
	ARIMAX-QR M.2	119,86	49,89	7,99
	ARIMAX-QR M.3	146,51	77,89	36,00
	ARIMAX-QR M.4	150,94	77,07	31,14
<i>Outflow</i> Rp5,000	TSR	74,52	43,00	25,22
	ARIMAX	119,71	59,29	21,13
	ARIMAX-QR M.1	195,92	78,44	6,19
	ARIMAX-QR M.2	135,50	62,38	19,51
	ARIMAX-QR M.3	163,53	88,36	34,27
	ARIMAX-QR M.4	174,75	86,07	25,44
<i>Outflow</i> Rp2,000	TSR	95,41	33,80	2,12
	ARIMAX	104,78	38,38	2,03
	ARIMAX-QR M.1	65,09	25,07	2,19
	ARIMAX-QR M.2	106,35	40,58	4,95
	ARIMAX-QR M.3	93,90	39,54	7,24
	ARIMAX-QR M.4	96,33	38,41	6,43


**Tabel 4. 51** Perbandingan Nilai Kesalahan Ramalan *Out-sample* tiap Metode  
(lanjutan)

<b>Pecahan</b>	<b>Metode</b>	<b>RMSE</b>	<b>MAE</b>	<b>MdAE</b>
<i>Outflow</i> Rp1,000	TSR	1,27	0,58	0,21
	ARIMAX	0,96	0,53	0,28
	ARIMAX-QR M.1	9,48	3,49	0,30
	ARIMAX-QR M.2	1,01	0,58	0,35
	ARIMAX-QR M.3	9,53	5,88	2,00
	ARIMAX-QR M.4	4,59	3,10	1,88
<i>Inflow</i> Rp100,000	TSR	751,64	634,19	642,74
	ARIMAX	636,21	456,37	274,53
	ARIMAX-QR M.1	1461,06	932,24	537,16
	ARIMAX-QR M.2	752,22	510,13	346,04
	ARIMAX-QR M.3	1202,43	794,88	525,87
	ARIMAX-QR M.4	1253,16	816,31	486,45
<i>Inflow</i> Rp50,000	TSR	556,38	381,37	238,86
	ARIMAX	365,18	271,12	217,65
	ARIMAX-QR M.1	292,89	243,48	202,68
	ARIMAX-QR M.2	391,66	267,95	211,71
	ARIMAX-QR M.3	272,19	234,73	205,50
	ARIMAX-QR M.4	278,99	242,62	206,48
<i>Inflow</i> Rp20,000	TSR	48,08	26,42	18,32
	ARIMAX	60,64	41,05	25,89
	ARIMAX-QR M.1	55,41	34,34	18,54
	ARIMAX-QR M.2	60,11	40,67	25,31
	ARIMAX-QR M.3	42,70	29,94	18,08
	ARIMAX-QR M.4	65,35	41,20	21,54
<i>Inflow</i> Rp10,000	TSR	37,20	26,29	13,62
	ARIMAX	41,60	23,83	11,79
	ARIMAX-QR M.1	88,48	49,95	21,04
	ARIMAX-QR M.2	41,29	23,78	11,71
	ARIMAX-QR M.3	39,93	22,58	10,98
	ARIMAX-QR M.4	46,24	26,91	10,62
<i>Inflow</i> Rp5,000	TSR	33,41	19,78	9,10
	ARIMAX	47,79	37,96	32,25
	ARIMAX-QR M.1	34,06	23,31	13,54
	ARIMAX-QR M.2	32,96	19,68	8,64
	ARIMAX-QR M.3	39,64	21,38	10,79
	ARIMAX-QR M.4	37,15	19,17	8,57
<i>Inflow</i> Rp2,000	TSR	14,82	12,96	12,17
	ARIMAX	23,60	17,59	7,97
	ARIMAX-QR M.1	17,92	13,41	8,36
	ARIMAX-QR M.2	15,60	13,81	11,87
	ARIMAX-QR M.3	14,85	11,03	7,56
	ARIMAX-QR M.4	16,52	12,51	8,58

**Tabel 4.51** Perbandingan Nilai Kesalahan Ramalan *Out-sample* tiap Metode (lanjutan)


Pecahan	Metode	RMSE	MAE	MdAE
<i>Inflow</i>	TSR	1,00	0,88	0,82
Rp1.000	ARIMAX	1,87	1,51	1,00
	ARIMAX-QR M.1	1,30	1,00	0,77
	ARIMAX-QR M.2	1,86	1,50	1,00
	ARIMAX-QR M.3	3,57	2,60	1,63
	ARIMAX-QR M.4	1,06	0,81	0,57

Pada Tabel 4.51 ditunjukkan perbandingan nilai kesalahan ramalan data *out-sample* dari tiap metode. Pada data *outflow* pecahan Rp100.000,00, nilai RMSE terkecil dihasilkan oleh metode ARIMAX-QR model 2, namun nilai MAE dan MdAE terkecil dihasilkan oleh model *time series regression*, sehingga model *time series regression* yang terpilih menjadi model terbaik untuk memodelkan data *outflow* pecahan Rp100.000,00. Untuk perbandingan kesalahan ramalan untuk data *inflow* dan *outflow* pecahan yang lain dapat dilihat pada Tabel 4.51. Salah satu cara untuk mengetahui apakah metode *hybrid* membuat peningkatan terhadap hasil ramalan dapat dilihat berdasarkan rasio kesalahan ramalannya terhadap model *benchmark*. Pada penelitian ini, metode *time series regression* akan digunakan sebagai model *benchmark*. Dari ketiga kriteria kebaikan model, akan digunakan rasio RMSE dan MdAE untuk membandingkan performa antar metode. Rasio perbandingan RMSE dan MdAE pada ramalan *out-sample* data *outflow* per pecahan disajikan pada Gambar 4.54.




**Gambar 4.55** Rasio RMSE (a) dan MdAE (b) antar metode pada ramalan *out-sample* data *outflow*

Gambar 4.55 menunjukkan perbandingan rasio RMSE dan MdAE pada metode ARIMAX dan ARIMAX-QR baik model 1 hingga model 4 terhadap model *times series regression*. Berdasarkan kriteria RMSE, metode ARIMAX-QR mampu menurunkan nilai kesalahan ramalan pada beberapa pecahan seperti pada pecahan Rp10.000,00; Rp20.000,00; Rp50.000,00; dan Rp100.000,00 dibanding metode *time series regression*. Apabila memperhatikan kriteria MdAE, nilai metode ARIMAX-QR tidak terlalu memberikan dampak penurunan nilai kesalahan ramalan dibanding model *time series regression* untuk nilai ramalan *out-sample* data *outflow* per pecahan.




**Gambar 4.56** Rasio RMSE (a) dan MdAE (b) antar metode pada ramalan *out-sample* data *inflow*

Pada peramalan *out-sample* data *inflow* per pecahan, rasio perbandingan kesalahan ramalan dengan kriteria RMSE dan MdAE ditunjukkan pada Gambar 4.56. Dari gambar tersebut nampak bahwa pada beberapa pecahan, metode ARIMAX-QR model 1 hingga model 4 mampu menurunkan kesalahan ramalan dibanding model *time series regression*. Selain memperhatikan kesalahan ramalan titik, apabila memperhatikan jumlah ramalan interval yang *crossing* didapatkan hasil bahwa semakin banyak jumlah input yang digunakan maka kemungkinan *crossing* antar kuantil semakin besar. Hal ini ditunjukkan dengan jumlah *crossing* pada ARIMAX-QR model 2 yang menggunakan 1 input lebih sedikit dibanding model lainnya.



**Gambar 4.57** Perbandingan RMSE Adaptive Ramalan *Out-sample* Data *Outflow* Per Pecahan Tiap Metode



**Gambar 4.58** Perbandingan RMSE Adaptive Ramalan *Out-sample* Data Inflow Per Pecahan Tiap Metode

Dari nilai RMSE *out-sample* yang dihasilkan tiap metode untuk masing-masing data *inflow* dan *outflow* selanjutnya dilakukan perbandingan akurasi dari masing-masing metode menggunakan plot nilai RMSE adaptifnya, untuk mengetahui

kebaikan ramalan tiap metode baik digunakan untuk meramalkan berapa periode ke depan. Plot perbandingan RMSE adaptif antar metode disajikan pada Gambar 4.56 dan 4.57. Pada peramalan *out-sample* data *outflow* Rp100.000,00 menggunakan metode *time series regression*, berdasarkan nilai RMSE adaptifnya, metode *time series regression* ini baik digunakan untuk 4 periode ke depan. Hal yang sama ditunjukkan dari RMSE adaptif menggunakan metode ARIMAX, dan ARIMAX-QR model 1 hingga model 4. Dari keempat metode tersebut, RMSE adaptif dari metode TSR dan ARIMAX bernilai lebih kecil dibanding menggunakan metode lainnya untuk peramalan 4 periode awal, sedangkan pada peramalan periode selanjutnya nilai RMSE meningkat.

Model terbaik pada tiap data yang terpilih berdasarkan perbandingan nilai kesalahan ramalan pada semua model berdasarkan nilai ramalan *out-sample* disajikan pada Tabel 4.52.

**Tabel 4.52** Perbandingan Kebaikan Model Ramalan tiap Data

Data	Pecahan	Metode	RMSE	MAE	MdAE	Out
<i>Outflow</i>	Rp100.000	<i>Time Series Regression</i>	1,624,52	876,42	284,72	0/12
	Rp50.000	ARIMAX-QR Model 3	418,53	328,42	288,15	0/12
	Rp20.000	ARIMAX	147,64	66,83	15,61	1/12
	Rp10.000	ARIMAX	112,27	47,36	6,450	2/12
	Rp5.000	<i>Time Series Regression</i>	74,52	43,00	25,22	2/12
	Rp2.000	ARIMAX-QR Model 1	65,09	25,06	2,18	5/12*
	Rp1.000	ARIMAX	0,96	0,53	0,28	5/12
<i>Inflow</i>	Rp100.000	ARIMAX	636,21	456,37	274,53	0/12
	Rp50.000	ARIMAX-QR Model 3	272,18	234,72	205,49	0/12
	Rp20.000	ARIMAX-QR Model 3	42,69	29,94	18,07	3/12*
	Rp10.000	ARIMAX-QR Model 3	39,93	22,57	10,98	3/12*
	Rp5.000	ARIMAX-QR Model 2	33,41	19,78	9,10	3/12
	Rp2.000	ARIMAX-QR Model 3	14,85	11,03	7,55	3/12*
	Rp1.000	ARIMAX-QR Model 4	1,06	0,81	0,57	4/12

**Keterangan:** \* = terdapat hasil ramalan yang *crossing* antar kuantil

Model terbaik yang terpilih untuk meramalkan *outflow* pecahan Rp100.000,00 adalah *time series regression*, sedangkan untuk pecahan lainnya dapat dilihat pada Tabel 4.54. Terdapat 8 pecahan uang kertas yang model terbaiknya adalah menggunakan model *hybrid* ARIMAX-QR, yaitu ARIMAX-QR model 1, model 2 dan model 4 unggul di masing-masing 1 pecahan dan 5 pecahan lainnya baik diramalkan menggunakan metode ARIMAX-QR model 3. Metode klasik *time series regression* menjadi model terbaik untuk memodelkan 2 pecahan uang kertas dan ARIMAX juga masih menjadi model terbaik untuk memodelkan pecahan uang kertas di 4 pecahan, hal ini dikarenakan pada pemodelan *time series regression* dan ARIMAX dilakukan beberapa *treatment* tertentu seperti melakukan transformasi. Berikut dituliskan model terbaik dari masing-masing data.

- a. Model *Time Series regression* untuk *outflow* pecahan Rp100.000,00

$$\begin{aligned} \ln(Y_{1,t}) = & 0,008 t - 0,995 D_{2,t} - 1,425 D_{3,t} + 0,008 tD_{3,t} + 6,025 M_{1,t} + \\ & 6,449 M_{2,t} + 6,896 M_{3,t} + 6,93 M_{4,t} + 6,89 M_{5,t} + 7,21 M_{6,t} + \\ & 7,023 M_{7,t} + 6,861 M_{8,t} + 6,94 M_{9,t} + 6,76 M_{10,t} + 6,40 M_{11,t} + \\ & 7,404 M_{12,t} - 0,592 V_{1,t} + 0,459 V_{2,t} + 0,961 V_{3,t} + 0,900 V_{4,t} + \\ & 1,088 V_{1,t-1} + 0,728 V_{2,t-1} + a_t \end{aligned}$$

- b. Model ARIMAX-QR untuk *outflow* pecahan Rp50.000,00

$$\begin{aligned} Y_{2,t} = & 7,340 t - 483,575 D_{2,t} - 1181,809 D_{3,t} - 6,516 tD_{2,t} + 5,537 tD_{3,t} + \\ & 459,019 M_{1,t} + 696,531 M_{2,t} - 1039,291 M_{3,t} + 1041,857 M_{4,t} + \\ & 1022,912 M_{5,t} + 1276,733 M_{6,t} + 1267,399 M_{7,t} - 1042,910 M_{8,t} + \\ & 620,608 M_{9,t} + 798,929 M_{10,t} + 845,327 M_{11,t} + 1684,417 M_{12,t} - \\ & 545,414 V_{1,t} + 1295,932 V_{2,t} + 2255,623 V_{3,t} + 2000,848 V_{4,t} + \\ & 2636,415 V_{1,t-1} + 879,561 V_{2,t-1} + 67,777 V_{3,t-1} + 129,597 V_{4,t-1} + \\ & \hat{a}_{2,t}(\tau) + \varepsilon_t \end{aligned}$$



- Untuk  $\tau = 0,50$

$$\hat{a}_{2,t}(0,50) = 0,249 a_{2,t-12} - 0,232 a_{2,t-15} + 0,006 \hat{Z}_{2,t}$$

- Untuk  $\tau = 0,025$

$$\hat{a}_{2,t}(0,025) = 0,236 a_{2,t-12} - 0,105 a_{2,t-15} + 0,555 \hat{Z}_{2,t}$$

- Untuk  $\tau = 0,975$

$$\hat{a}_{2,t}(0,975) = -0,228 a_{2,t-12} - 0,072 a_{2,t-15} + 0,583 \hat{Z}_{2,t}$$

- c. Model variasi kalender dengan ARIMA (1,0,[12]) untuk *outflow* pecahan Rp20.000,00

$$\begin{aligned} \ln(Y_{3,t}) = & -1,195 D_{3,t} - 0,017 tD_{3,t} + 4,558 M_{1,t} + 4,689 M_{2,t} + \\ & 4,745 M_{3,t} + 4,993 M_{4,t} + 5,111 M_{5,t} + 5,210 M_{6,t} + \\ & 4,929 M_{7,t} + 4,348 M_{8,t} + 3,697 M_{9,t} + 3,729 M_{10,t} + \\ & 4,060 M_{11,t} + 4,796 M_{12,t} + 1,793 V_{2,t} + 2,453 V_{3,t} + \\ & 2,329 V_{4,t} + 2,247 V_{1,t-1} + 2,299 V_{2,t-1} + 1,685 V_{3,t-1} + \\ & 1,328 V_{4,t-1} + \frac{(1 + 0,385 B^{12})}{(1 - 0,475 B)} a_t \end{aligned}$$

- d. Model variasi kalender dengan ARIMA([12],0,[1,23]) untuk *outflow* pecahan Rp10.000,00

$$\begin{aligned} \ln(Y_{4,t}) = & -0,698 D_{3,t} - 0,009 tD_{2,t} + 3,962 M_{1,t} + 3,857 M_{2,t} + \\ & 4,080 M_{3,t} + 4,438 M_{4,t} + 4,518 M_{5,t} + 4,650 M_{6,t} + \\ & 4,373 M_{7,t} + 3,849 M_{8,t} + 3,373 M_{9,t} + 3,164 M_{10,t} + \\ & 3,329 M_{11,t} + 3,996 M_{12,t} + 2,018 V_{2,t} + 2,126 V_{3,t} + \\ & 2,170 V_{4,t} + 1,706 V_{1,t-1} + 1,856 V_{2,t-1} + 1,290 V_{3,t-1} + \\ & 0,885 V_{4,t-1} + \frac{(1 + 0,403 B + 0,597 B^{23})}{(1 - 0,4464 B^{12})} a_t \end{aligned}$$

- e. Model *time Series regression* untuk *outflow* pecahan Rp5.000,00

$$Y_{5,t} = 16,66M_{6,t} + 19,34M_{8,t} + 52,64V_{3,t} + 22,59V_{4,t} + 112,03V_{1,t-1} + 110,99V_{2,t-1} - 0,161Y_{5,t-1} + 0,055Y_{5,t-10} + 0,593Y_{5,t-12} + 0,580Y_{5,t-23} + a_t$$

- f. Model ARIMAX-QR untuk *outflow* pecahan Rp2.000,00

- Untuk  $\tau = 0,50$

$$Y_{6,t}(0,50) = 0,06t + 13,415D_{2,t} - 0,821D_{3,t} - 0,765tD_{2,t} - 0,539M_{1,t} - 0,292M_{2,t} - 0,377M_{3,t} + 1,047M_{4,t} + 1,61M_{5,t} + 2,292M_{6,t} - 45,674M_{7,t} - 4,026M_{8,t} - 1,967M_{9,t} - 2,708M_{10,t} - 2,894M_{11,t} - 6,637V_{2,t} + 69,241V_{3,t} + 138,130V_{4,t} + 259,317V_{2,t-1} + 75,349V_{3,t-1} + 75,349V_{4,t-1} + 0,676\hat{Z}_{6,t} + a_t$$

- Untuk  $\tau = 0,025$

$$Y_{6,t}(0,025) = 0,003t + 13,418D_{2,t} + 1,185D_{3,t} - 0,870tD_{2,t} - 1,946M_{1,t} - 2,260M_{2,t} - 1,254M_{3,t} - 0,677M_{4,t} - 1,811M_{5,t} - 0,148M_{6,t} - 46,594M_{7,t} - 6,886M_{8,t} - 9,231M_{9,t} - 3,158M_{10,t} - 3,244M_{11,t} - 16,263V_{2,t} + 73,592V_{3,t} + 143,107V_{4,t} + 263,197V_{2,t-1} + 36,802V_{3,t-1} + 10,453V_{4,t-1} + 0,664\hat{Z}_{6,t} + a_t$$

- Untuk  $\tau = 0,975$

$$Y_{6,t}(0,975) = 0,022t + 61,655D_{2,t} + 4,109D_{3,t} - 3,715tD_{2,t} - 2,317M_{1,t} - 3,734M_{2,t} - 4,836M_{3,t} - 5,829M_{4,t} + 28,962M_{5,t} - 6,17M_{6,t} + 13,949M_{7,t} - 6,003M_{8,t} - 5,481M_{9,t} - 5,484M_{10,t} - 5,467M_{11,t} - 38,270V_{2,t} + 48,323V_{3,t} + 25,181V_{4,t} + 241,819V_{2,t-1} - 9,49V_{3,t-1} - 14,671V_{4,t-1} + 1,375\hat{Z}_{6,t} + a_t$$

g. Model ARIMAX untuk *Outflow* Pecahan Rp1.000,00

$$\begin{aligned} \ln(Y_{7,t}) = & 2,89 D_{3,t} - 2,97 D_{3,t} - 0,05 tD_{2,t} + 2,51 M_{1,t} + 2,45 M_{2,t} + \\ & 2,62 M_{3,t} + 2,551 M_{4,t} + 2,527 M_{5,t} + 2,492 M_{6,t} + 2,519 M_{7,t} + \\ & 2,741 M_{8,t} + 2,250 M_{9,t} + 2,025 M_{10,t} + 1,973 M_{11,t} + 2,488 M_{12,t} + \\ & 1,852 V_{2,t} + 1,840 V_{3,t} + 2,969 V_{4,t} + 1,282 V_{1,t-1} + 2,158 V_{2,t-1} + \\ & 1,265 V_{4,t-1} + \frac{1}{(1-0,541B)} a_t \end{aligned}$$

h. Model variasi kalender dengan ARIMA([3],0,0) untuk *Inflow* Pecahan Rp100.000,00

$$\begin{aligned} \ln(Y_{8,t}) = & 0,009 t - 0,963 D_{2,t} - 1,027 D_{3,t} + 0,005 tD_{3,t} + 7,499 M_{1,t} + \\ & 6,948 M_{2,t} + 6,754 M_{3,t} + 6,778 M_{4,t} + 6,847 M_{5,t} + 6,689 M_{6,t} + \\ & 6,907 M_{7,t} + 7,026 M_{8,t} + 6,897 M_{9,t} + 7,074 M_{10,t} + 6,769 M_{11,t} + \\ & 6,583 M_{12,t} + 1,006 V_{1,t} + 0,892 V_{2,t} + 0,312 V_{3,t} - 0,561 V_{4,t} - \\ & 0,197 V_{2,t-1} - 0,086 V_{3,t-1} + 0,040 V_{4,t-1} + \frac{1}{(1-0,1575B^3)} a_t \end{aligned}$$

i. Model ARIMAX-QR untuk *Inflow* Pecahan Rp50.000,00

$$\begin{aligned} Y_{9,t} = & 13,932 t - 773,607 D_{2,t} - 1388,706 D_{3,t} - 7,155 tD_{2,t} + 1,727 tD_{3,t} + \\ & 1945,928 M_{1,t} + 1206,431 M_{2,t} + 980,682 M_{3,t} + 1022,067 M_{4,t} + \\ & 1078,031 M_{5,t} + 897,188 M_{6,t} + 1116,426 M_{7,t} - 1219,485 M_{8,t} + \\ & 980,289 M_{9,t} + 1191,112 M_{10,t} + 887,937 M_{11,t} + 711,870 M_{12,t} + \\ & 2095,427 V_{1,t} + 1562,229 V_{2,t} + 531,107 V_{3,t} - 437,988 V_{4,t} + \\ & 246,520 V_{1,t-1} + 439,316 V_{2,t-1} + 1118,772 V_{3,t-1} + 1967,883 V_{4,t-1} + \\ & \hat{a}_{9,t}(\tau) + \varepsilon_t \end{aligned}$$

- Untuk  $\tau = 0,50$

$$\hat{a}_{9,t}(0,50) = 0,004\hat{Z}_{9,t}$$

- Untuk  $\tau = 0,025$

$$\hat{a}_{9,t}(0,025) = -0,406\hat{Z}_{9,t}$$

- Untuk  $\tau = 0,975$

$$\hat{a}_{9,t}(0,975) = 0,417\hat{Z}_{9,t}$$

j. Model ARIMAX-QR untuk *Inflow* Pecahan Rp20.000,00

$$\begin{aligned} Y_{10,t} = & -1,117 t - 109,614 D_{2,t} - 154,311 D_{3,t} + 1,032 tD_{2,t} + 1,486 tD_{3,t} + \\ & 232,705 M_{1,t} + 199,282 M_{2,t} + 184,140 M_{3,t} + 175,323 M_{4,t} + \\ & 171,463 M_{5,t} + 162,299 M_{6,t} + 174,222 M_{7,t} + 199,612 M_{8,t} + \\ & 198,333 M_{9,t} + 190,756 M_{10,t} + 199,544 M_{11,t} + 184,810 M_{12,t} + \\ & 93,829 V_{1,t} + 26,582 V_{2,t} - 27,209 V_{3,t} - 57,337 V_{4,t} + 101,776 V_{1,t-1} + \\ & 68,385 V_{2,t-1} + 114,312 V_{3,t-1} + 119,443 V_{4,t-1} + \hat{a}_{10,t}(\tau) + \varepsilon_t \end{aligned}$$

- Untuk  $\tau = 0,50$

$$\begin{aligned} \hat{a}_{10,t}(0,50) = & 0,419a_{10,t-1} + 0,277a_{10,t-11} - 0,163a_{10,t-13} + \\ & 0,210a_{10,t-23} + 0,032\hat{Z}_{10,t} \end{aligned}$$

- Untuk  $\tau = 0,025$

$$\begin{aligned} \hat{a}_{10,t}(0,025) = & 0,685a_{10,t-1} + 0,745a_{10,t-11} - 0,246a_{10,t-13} + \\ & 0,352a_{10,t-23} - 0,479\hat{Z}_{10,t} \end{aligned}$$

- Untuk  $\tau = 0,975$

$$\begin{aligned} \hat{a}_{10,t}(0,975) = & 0,062a_{10,t-1} + 0,361a_{10,t-11} - 0,119a_{10,t-13} + \\ & 0,139a_{10,t-23} + 0,490\hat{Z}_{10,t} \end{aligned}$$

k. Model ARIMAX-QR untuk *Inflow* Pecahan Rp10.000,00

$$\begin{aligned}
 Y_{11,t} = & -1,128 t - 23,481 D_{2,t} - 70,657 D_{3,t} + 0,847 t D_{2,t} + 1,572 t D_{3,t} + \\
 & 127,281 M_{1,t} + 100,744 M_{2,t} + 88,978 M_{3,t} + 77,421 M_{4,t} + \\
 & 74,8717 M_{5,t} + 65,900 M_{6,t} + 75,034 M_{7,t} + 105,168 M_{8,t} + \\
 & 116,457 M_{9,t} + 102,914 M_{10,t} + 100,821 M_{11,t} + 94,226 M_{12,t} + \\
 & 35,472 V_{1,t} - 9,444 V_{2,t} - 42,779 V_{3,t} - 41,844 V_{4,t} + 101,438 V_{1,t-1} + \\
 & 54,489 V_{2,t-1} + 92,304 V_{3,t-1} + 62,181 V_{4,t-1} + \hat{a}_{11,t}(\tau) + \varepsilon_t
 \end{aligned}$$

- Untuk  $\tau = 0,50$

$$\begin{aligned}
 \hat{a}_{11,t}(0,50) = & 0,264a_{11,t-1} + 0,306a_{11,t-11} + 0,375a_{11,t-12} - \\
 & 0,139a_{11,t-13} + 0,294a_{11,t-23} - 0,217a_{11,t-24} + \\
 & 0,015\hat{Z}_{11,t}
 \end{aligned}$$

- Untuk  $\tau = 0,025$

$$\begin{aligned}
 \hat{a}_{11,t}(0,025) = & 0,955a_{11,t-1} + 0,221a_{11,t-11} + 0,357a_{11,t-12} + \\
 & 0,105a_{11,t-13} + 0,647a_{11,t-23} - 0,063a_{11,t-24} - \\
 & 0,774\hat{Z}_{11,t}
 \end{aligned}$$

- Untuk  $\tau = 0,975$

$$\begin{aligned}
 \hat{a}_{11,t}(0,975) = & 0,710a_{11,t-1} + 0,272a_{11,t-11} + 0,138a_{11,t-12} - \\
 & 0,306a_{11,t-13} + 0,228a_{11,t-23} - 0,561a_{11,t-24} + \\
 & 0,595\hat{Z}_{11,t}
 \end{aligned}$$

l. Model ARIMAX-QR untuk *Inflow* Pecahan Rp5.000,00

- Untuk  $\tau = 0,50$

$$Y_{12,t}(0,50) = 1,002\hat{Z}_{12,t}^* + \varepsilon_t$$

- Untuk  $\tau = 0,025$

$$Y_{12,t}(0,025) = 0,591\hat{Z}_{12,t}^* + \varepsilon_t$$

- Untuk  $\tau = 0,975$

$$Y_{12,t}(0,975) = 1,544\hat{Z}_{12,t}^* + \varepsilon_t$$

m. Model ARIMAX-QR untuk *Inflow* Pecahan Rp2.000,00

$$Y_{13,t} = 0,231 t - 6,241 D_{2,t} + 29,191 D_{3,t} + 1,744 t D_{2,t} - 4,603 M_{1,t} - 7,138 M_{2,t} - 11,060 M_{3,t} - 17,975 M_{4,t} - 21,977 M_{5,t} - 24,974 M_{6,t} - 20,796 M_{7,t} - 0,344 M_{8,t} + 25,651 M_{9,t} + 25,240 M_{10,t} + 6,298 M_{11,t} - 11,831 V_{1,t} - 36,572 V_{2,t} - 21,041 V_{3,t} - 22,186 V_{4,t} + 28,242 V_{1,t-1} - 22,778 V_{2,t-1} + 20,315 V_{3,t-1} + 25,410 V_{4,t-1} + \hat{a}_{13,t}(\tau) + \varepsilon_t$$

- Untuk  $\tau = 0,50$

$$\hat{a}_{13,t}(0,50) = 0,381a_{13,t-1} - 0,169a_{13,t-14} - 0,032\hat{Z}_{13,t}$$

- Untuk  $\tau = 0,025$

$$\hat{a}_{13,t}(0,025) = 0,086a_{13,t-1} + 0,136a_{13,t-14} - 0,780\hat{Z}_{13,t}$$

- Untuk  $\tau = 0,975$

$$\hat{a}_{13,t}(0,975) = 0,544a_{13,t-1} - 0,007a_{13,t-14} + 0,593\hat{Z}_{13,t}$$

n. Model ARIMAX-QR untuk *Inflow* Pecahan Rp1.000,00

- Untuk  $\tau = 0,50$

$$Y_{14,t}(0,50) = 0,230Y_{t-1} - 0,058Y_{t-3} - 0,002Y_{t-7} - 0,044Y_{t-8} + 0,205Y_{t-11} + 0,392Y_{t-12} + 0,229Y_{t-23} - 0,176Y_{t-24} + 0,209\hat{Y}_{14,t}^{(1)} + a_t$$

- Untuk  $\tau = 0,025$

$$Y_{14,t}(0,025) = 0,209Y_{t-1} - 0,025Y_{t-3} + 0,071Y_{t-7} - 0,092Y_{t-8} + 0,006Y_{t-11} + 0,216Y_{t-12} + 0,243Y_{t-23} - 0,099Y_{t-24} + 0,138\hat{Y}_{14,t}^{(1)} + a_t$$

- Untuk  $\tau = 0,975$

$$Y_{14,t}(0,975) = 0,111Y_{t-1} - 0,258Y_{t-3} - 0,147Y_{t-7} + 0,149Y_{t-8} + 0,460Y_{t-11} - 0,074Y_{t-12} + 0,465Y_{t-23} + 0,713Y_{t-24} + 0,291\hat{Y}_{14,t}^{(1)} + a_t$$

Berdasarkan model terbaik dari masing-masing data *inflow* dan *outflow* maka langkah selanjutnya adalah melakukan peramalan untuk data 12 periode ke depan yakni data tahun 2017

mulai bulan Januari hingga Desember. Data ramalan untuk data *outflow* per pecahan mulai Januari 2017 hingga Desember 2017 disajikan pada Tabel 4.53.

**Tabel 4.53** Ramalan *Outflow* Per Pecahan di Jawa Timur periode Januari 2017-Desember 2017

Bulan	<i>Outflow (Miliar Rupiah)</i>			
	Rp100.000	Rp50.000	Rp20.000	Rp10.000
Januari	1497,110	1387,331	49,111	60,793
Februari	2323,888	1729,648	34,286	10,652
Maret	3592,881	1849,985	38,573	22,269
April	3893,462	2226,002	51,082	45,935
Mei	3812,056	2394,563	352,184	319,056
Juni	13097,581	4539,309	661,615	505,528
Juli	4470,837	2205,873	20,593	15,988
Agustus	3865,445	1860,116	12,976	10,260
September	4232,828	1914,871	9,241	7,462
Oktober	3679,139	1990,251	12,186	12,090
November	3667,609	2160,083	16,643	18,888
Desember	7085,473	2824,756	41,532	42,381

**Tabel 4.53** Ramalan *Outflow* Per Pecahan di Jawa Timur periode Januari 2017-Desember 2017 (lanjutan)

Bulan	<i>Outflow (Miliar Rupiah)</i>		
	Rp5.000	Rp2.000	Rp1.000
Januari	26,741	4,014	0,590
Februari	8,574	3,116	0,621
Maret	7,038	6,670	0,722
April	-18,769	10,176	0,721
Mei	495,411	141,697	0,671
Juni	620,330	287,419	4,101
Juli	-87,628	-43,765	0,762
Agustus	39,813	-4,448	0,986
September	-1,610	-6,798	0,562
Oktober	6,893	0,421	0,407
November	18,510	2,555	0,405
Desember	24,986	7,607	0,618

Pada Tahun 2017, Hari Raya Idul Fitri terjadi pada minggu ke-4 bulan Juni. Pada Tabel 4.53, nilai *outflow* pada pecahan uang kertas Rp100.000,00, Rp50.000,00, Rp20.000,00, Rp10.000,00, Rp5.000,00, Rp2.000,00 dan Rp1.000,00 diprediksi akan meningkat dan tinggi pada bulan Juni 2017, yaitu di saat bulan terjadinya Hari Raya Idul Fitri. Hal ini menunjukkan bahwa hasil ramalan memiliki pola yang sesuai dengan pola pada data tahun-tahun sebelumnya yakni apabila Hari Raya Idul Fitri terjadi pada minggu keempat maka nilai *outflow* akan tinggi pada bulan saat terjadinya Hari Raya Idul Fitri. Nilai *outflow* per pecahan diprediksi tinggi pada bulan Desember, yang diduga disebabkan adanya perayaan Natal dan Tahun Baru yang menyebabkan kebutuhan uang di masyarakat juga cenderung meningkat. *Outflow* pecahan Rp20.000,00, Rp10.000,00, Rp5.000,00 dan Rp2.000,00 diprediksi akan meningkat pada bulan Mei 2017 yaitu satu bulan sebelum terjadinya Hari Raya Idul Fitri, dimana pecahan-pecahan ini yang menjadi uang kertas yang paling banyak digemari untuk digunakan masyarakat dalam merayakan Hari Raya Idul Fitri, sedangkan pecahan uang kertas Rp100.000,00 dan Rp50.000,00 permintaannya tidak sebesar nominal kecil.

Berdasarkan pola data pada tahun-tahun sebelumnya, terjadi lonjakan kebutuhan uang yang sangat tinggi pada bulan terjadinya Hari Raya Idul Fitri atau pada satu bulan sebelum terjadinya dibanding bulan-bulan lainnya. Hal ini menyebabkan varians data menjadi besar. Nilai ramalan *outflow* pada pecahan Rp5.000,00 bernilai negatif pada bulan April, Juli dan September karena perbedaan *outflow* yang besar antara bulan yang tidak terkena efek variasi kalender dan bulan yang terkena efek variasi kalender tersebut. Untuk pecahan Rp2.000,00 nilai ramalan bernilai negatif untuk bulan Juli, Agustus dan September. Pada penelitian ini, nilai ramalan untuk tahun 2017 berfokus pada model terbaik yang terpilih berdasarkan kriteria kebaikan model ramalan *out-sample*.



**Tabel 4.54** Ramalan *Inflow* Per Pecahan di Jawa Timur periode Januari 2017-Desember 2017

Bulan	<i>Inflow (Miliar Rupiah)</i>			
	Rp100.000	Rp50.000	Rp20.000	Rp10.000
Januari	7003,166	3216,442	134,105	109,360
Februari	4205,496	2489,919	112,985	101,486
Maret	3642,617	2278,742	88,948	78,912
April	3646,867	2335,480	69,654	55,319
Mei	4146,101	2408,539	67,014	53,287
Juni	1978,253	1803,266	39,998	36,864
Juli	4346,876	4451,122	271,530	239,304
Agustus	4969,498	2597,257	160,844	187,402
September	4434,254	2373,189	119,031	111,469
Oktober	5363,228	2599,959	104,364	103,052
November	4012,706	2311,866	108,456	93,652
Desember	3378,450	2151,275	87,169	80,154

**Tabel 4.54** Ramalan *Inflow* Per Pecahan di Jawa Timur periode Januari 2017-Desember 2017 (lanjutan)

Bulan	<i>Inflow (Miliar Rupiah)</i>		
	Rp5.000	Rp2.000	Rp1.000
Januari	82,508	46,759	2,669
Februari	78,389	44,897	2,604
Maret	62,372	39,547	2,147
April	40,887	24,518	1,761
Mei	42,416	25,654	2,626
Juni	31,669	4,226	1,292
Juli	193,189	7,039	1,864
Agustus	319,980	51,892	1,899
September	206,970	77,461	1,756
Oktober	136,676	75,380	2,241
November	109,397	53,504	1,957
Desember	90,581	49,108	2,023

Berdasarkan hasil ramalan untuk tahun 2017, *inflow* pecahan Rp100.000,00 diprediksi mencapai nilai paling tinggi pada bulan Januari 2017 yang diperkirakan terjadi karena pada bulan sebelumnya (Desember 2016) terjadi perayaan Natal dan Tahun Baru, dimana masyarakat cenderung menyetorkan uangnya setelah melakukan perayaan tersebut dibanding pada bulan-bulan

lain. Hal yang sama terjadi untuk pecahan Rp1.000,00. Untuk *inflow* pecahan Rp50.000,00, Rp20.000,00, Rp10.000,00 tertinggi diprediksi akan terjadi pada bulan Juli 2017 yaitu satu bulan setelah terjadinya Hari Raya Idul Fitri, dan bahkan pada bulan Agustus 2017, nilai *inflow* untuk pecahan-pecahan ini diprediksi masih tinggi.

Bank Indonesia memerlukan suatu rencana dalam mencapai tujuannya yaitu memenuhi kebutuhan uang di masyarakat, salah satunya dengan menyusun Rencana Kebutuhan Uang (RKU) yang meliputi nilai *inflow* dan *outflow*. Setelah Rencana Cetak Uang (RKU) dan Rencana Pengadaan Uang (RPU) yang diusulkan oleh Departemen Pengelolaan Uang disetujui oleh Dewan Gubernur BI, maka selanjutnya BI Pusat menghimpun usulan *inflow* dan *outflow* dari tiap KPw. Nilai ramalan *inflow* dan *outflow* per pecahan uang kertas pada tahun 2017 yang dihasilkan ini dapat menjadi usulan jumlah pengadaan uang untuk Jawa Timur. KPw Jawa Timur dapat mengusulkan hasil ramalan *inflow* dan *outflow* ini kepada kantor Pusat Bank Indonesia, dan menjadi bahan pertimbangan oleh pihak pusat dalam menentukan jumlah pengadaan uang di Jawa Timur pada tahun 2017.

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan maka dapat ditarik kesimpulan sebagai berikut.

1. Karakteristik *inflow* dan *outflow* di Jawa Timur pada periode Januari 2003 hingga Desember 2016 mempunyai pola musiman dan dipengaruhi oleh efek Hari Raya Idul Fitri, Natal dan Tahun Baru.
2. Secara umum, berdasarkan kriteria RMSE, MAE dan MdAE, model *time series regression* baik digunakan untuk meramalkan data *outflow* pecahan Rp.100.000,00 dan Rp5.000,00. Metode ARIMAX baik digunakan untuk meramalkan data *outflow* Rp20.000,00, Rp10.000,00 dan Rp5.000,00 serta pada peramalan *inflow* Rp100.000,00 di Jawa Timur. Pecahan lainnya yang tidak disebutkan sebelumnya baik diramalkan menggunakan metode ARIMAX-*Quantile Regression*.
3. Pada pemodelan data *inflow* dan *outflow* model ARIMAX-*Quantile Regression* lebih unggul dibanding metode individu yang lainnya. Metode ARIMAX-QR menggunakan model 3 menghasilkan nilai ramalan yang lebih baik dibandingkan model lainnya. ARIMAX-QR model 3 merupakan model terbaik untuk 5 dari 12 pecahan, sedangkan model 1, 2 dan 4 hanya 1 dari 12 pecahan. Metode ARIMAX masih menjadi model terbaik untuk 4 dari 12 pecahan, sedangkan model *time series regression* untuk 2 pecahan. Hal ini menunjukkan keunggulan metode ARIMAX-QR dibanding metode klasik. Hasil ini ditunjukkan pula pada studi simulasi yang menunjukkan bahwa metode ARIMAX-QR model 2 menjadi model terbaik di kedua skenario.

## 5.2 Saran

Saran yang diberikan untuk penelitian selanjutnya adalah sebaiknya melakukan deteksi *outlier* supaya asumsi residual distribusi normal pada penelitian selanjutnya dapat terpenuhi. Untuk penelitian menggunakan *quantile regression* disarankan untuk menggunakan metode *bootstrap* atau algoritma yang dapat meminimalisir kemungkinan terjadinya *crossing* pada nilai ramalan tiap kuantil . Selanjutnya perlu dilakukan kajian yang mendalam untuk mengetahui kapan akan terjadi ramalan yang *crossing*.

## DAFTAR PUSTAKA

- Anders, U. & Korn, O. (1999). Model Selection in Neural Networks. *Neural Networks*, **12**, 309-323. doi: 10.1016/S0893-6080(98)00117-8
- Apriliadara, M., Suhartono, & Prastyo, D.D., (2016), "VARI-X Model for Currency Inflow and Outflow with Eid Fitr Effect in Indonesia", *AIP Conference Proceedings*, 1746, 020041.
- Armstrong, J. S. (2007). *Significance Test Harm Progress in Forecasting*. Retrieved from [http://repository.upenn.edu/marketing\\_papers/99](http://repository.upenn.edu/marketing_papers/99)
- Arunraj, N. S., & Ahrens, D. (2015). A Hybrid Seasonal Autoregressive Integrated Moving Average and Quantile Regression for Daily Food Sales Forecasting. *International Journal Production Economics*, **170**, 321-335. doi: 10.1016/j.ijpe.2015.09.039
- Bank Indonesia. (2013). *Laporan Sistem Pembayaran dan Pengelolaan Uang 2012*. Jakarta: Bank Indonesia
- Bank Indonesia. (2016a). *Perkembangan Uang Beredar*. Retrieved January 16, 2017, from <http://www.bi.go.id/id/publikasi/perkembangan/Default.aspx>.
- Bank Indonesia. (2016b). *Laporan Perekonomian Indonesia 2015*. Jakarta: Bank Indonesia
- Bank Indonesia. (2016c). *Metadata Uang Kartal yang Diedarkan*. Retrieved January 27, 2017, from <http://www.bi.go.id/id/statistik/metadata/SSKI/Contents/Default.aspx>.
- Bowerman, B. L., & O'Connell, R. T., (1993). *Forecasting and Time Series: An Applied Approach, Third Edition*. California: Duxbury Press, Wadsworth Inc.
- Cryer, J.D., & Chan, K. (2008). *Time Series Analysis: With Application in R*. USA: Springer Science+Business Media, LLC.

- Cade, B. S., & Noon, B. R. (2003). *A gentle introduction to quantile regression for ecologists. Frontiers in Ecology and the Environment*. **1** (8): 412–420. doi:10.1890/1540-9295 (2003)001[0412:AGITQR]2.0.CO;2
- Daniel, W. W. (1989). *Statistik Non Parametrik Terapan*. Alih Bahasa: Alex Tri Kantjono W. Jakarta : PT. Gramedia.
- Draper, N. R., & Smith, H. (1998). *Applied Regression Analysis, 3<sup>rd</sup> Edition* . New York: John Wiley & Sons, Inc.
- Gilliland, M. (2011). *Bussiness forecasting effectiveness*. Retrieved January 28, 2017, from <http://analytics-magazine.org/value-added-analysis-business-forecasting-effectiveness/>.
- Hanim, Y. M., & Suhartono. (2015). *Penerapan Regresi Time Series dan ARIMAX untuk Peramalan Inflow dan Outflow Uang Kartal di Jawa Timur, DKI Jakarta dan Indonesia*. Surabaya: Tugas Akhir, Institut Teknologi Sepuluh Nopember
- Huang, K., & Yu, T. H. (2015). Forecasting ICT development through quantile confidence intervals. *Journal of Business Research*, **68**, 2295–2298. doi: 10.1016/j.jbusres.2015.06.014
- Hyndman, R. J. (2010). *Why every statistician should know about cross-validation*. Retrieved March 04, 2017, from <http://robjhyndman.com/hyndsight/crossvalidation/>.
- Hyndman, R. J. (2014). *Generating Quantile Forecasts in R*. Retrieved March 05, 2017, from <http://robjhyndman.com/hyndsight/quantile-forecasts-in-r/>.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, **22**, 679-688. doi: 10.1016/j.ijforecast.2006.03.001

- Karomah, A., & Suhartono. (2014). Peramalan Netflow Uang Kartal dengan Model Variasi Kalender dan Model Autoregressive Distributed Lag (ARDL). *Jurnal Sains dan Seni ITS Vol.3* No.2, D103-D108.
- Koenker, R. (2005). *Quantile regression*. New York: Cambridge University Press.
- Koenker, R. & Bassett Jr., G. (1978). Regression Quantiles. *Econometrica*, **46**, 33-50. doi: 10.2307/1913643
- Kostenko, A.V. & Hyndman, R. J. (2008). *Forecasting without Significance Test?* Retrieved May 24, 2017, from <http://robjhyndman.com/hyndsight/quantile-forecasts-in-r/>.
- Lee, M. H., Suhartono, & Hamzah, N.A. (2010). Calendar Variation Model Based on ARIMAX for Forecasting Sales Data with Ramadhan Effect. *Regional Conference on Statistical Science*, 349-361. Malaysia: Universiti Teknologi MARA (UiTM)
- Li, L., Leng, S., Yang, J., & Yu, M. (2016). Stock Market Autoregressive Dynamics: A Multinational Comparative Study with Quantile Regression. *Mathematical Problems in Engineering Volume 2016*. Hindawi Publishing Corporation.
- Li, G., Xu, S., Li Z., Sun, Y., & Dong, G. (2012). Using Quantile Regression Approach to Analyze Price Movements of Agricultural Products in China. *Journal of Integrative Agriculture*, **11**(4), 674-683. doi: 10.1016/S2095-3119(12)60055-0
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International Journal of Forecasting*, **16**, 451-476. doi: 10.1016/S0169-2070(00)00057-1
- Sholikah, B. (2016). *BI Jatim Temukan 14.383 Uang Rupiah Palsu*. Retrieved January 26, 2017, from <http://www.republika>.

co.id/berita/ekonomi/keuangan/16/12/19/oifxce383-bi-jatim-temukan-14383-lembar-uang-rupiah-palsu.

- Sigalingging, H., Setiawan, E., & Sihalohe, H. D. (2004). *Kebijakan Pengedaran Uang di Indonesia*. Pusat Pendidikan dan Studi Kebanksentralan, Bank Indonesia.
- Solikin & Suseno. (2002). *Uang, Pengertian, Penciptaan dan Peranannya dalam Perekonomian*. Pusat Pendidikan dan Studi Kebanksentralan, Bank Indonesia.
- Suhartono, Lee, M.H., & Prastyo, D.D., (2015), "Two levels ARIMAX and Regression Models for Forecasting Time Series Data with Calendar Variation Effects", *AIP Conference Proceedings*, 1691, 050026
- Taylor, J. W. (2000). A Quantile Regression Neural Network Approach to Estimating the Conditional Density of Multiperiod Returns. *Journal of Forecasting*, **19**, 299-311.
- Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods*. New York : Pearson Education, Inc.
- Xu, Q., Tsui, K., Jiang, W., & Guo, H. (2016). *A Hybrid Approach for Forecasting Patient Visits in Emergency Department*. Wiley Online Library (wileyonlinelibrary.com). doi: 10.1002/qre.2095



## LAMPIRAN

### Lampiran 1 Data *Inflow* Per Pecahan Uang Kertas di Jawa Timur

Periode	Rp100.000	Rp50.000	Rp20.000	Rp10.000	Rp5.000	Rp2.000	Rp1.000
Jan-2003	1448.39	1382.306	285.044	155.9961	87.50084	-	50.45502
Feb-2003	931.61	920.6322	180.5533	99.71606	57.49452	-	36.18073
Mar-2003	936.3977	911.4684	157.2591	81.42938	45.04882	-	35.12428
Apr-2003	1072.514	1008.531	154.5944	73.12734	36.98781	-	21.54703
May-2003	1088.476	1051.934	157.3589	72.20865	36.28108	-	20.84597
Jun-2003	1115.937	1078.762	150.7983	61.79696	31.63354	-	20.93755
Jul-2003	1302.41	1128.381	161.531	69.33357	35.59949	-	23.73204
Aug-2003	1489.969	1312.785	153.8237	53.6523	29.17381	-	13.8078
Sep-2003	1228.782	1271.793	144.4599	61.52673	34.10492	-	15.13993
Oct-2003	1342.875	1349.263	177.4164	73.10056	39.72841	-	17.55473
Nov-2003	554.8543	710.6262	88.15694	41.25652	21.25776	-	6.513067
Dec-2003	2286.175	2570.388	326.2638	146.6957	78.44347	-	32.79281
...	...	...	...	...	...	...	...
Jan-2016	6088.02	3416.2	99.56086	92.39282	69.73815	32.41219	3.965683
Feb-2016	4336.594	2445.998	87.42708	81.81853	68.33493	35.35618	4.546036
Mar-2016	2971.59	1927.477	89.22446	81.84297	61.70293	35.85023	3.059655
Apr-2016	2754.983	1848.577	56.21592	48.84109	38.21625	21.98639	2.080299
May-2016	3743.42	2404.053	46.48358	40.77354	29.61425	16.87348	1.545764
Jun-2016	2787.628	1610.151	36.4355	28.17626	20.85424	12.41071	1.166932
Jul-2016	9289.314	4632.1	244.4719	153.8072	66.5647	15.92828	1.702962
Aug-2016	3660.01	2499.499	306.3371	346.1678	305.4948	76.68489	2.976296
Sep-2016	3057.191	2282.853	149.1258	143.1537	197.8716	84.65254	2.893403
Oct-2016	3721.599	2402.308	112.1305	94.87661	124.1762	98.67444	2.728173
Nov-2016	3317.74	2177.62	119.7774	98.5718	93.032	63.19399	3.771706
Dec-2016	3511.747	2107.949	86.618	73.77569	85.34534	38.43076	2.065277

## Lampiran 2 Data *Outflow* Per Pecahan Uang Kertas di Jawa Timur

Periode	Rp100.000	Rp50.000	Rp20.000	Rp10.000	Rp5.000	Rp2.000	Rp1.000
Jan-2003	747.5255	644.9412	106.7865	58.79929	28.28686	0	10.62999
Feb-2003	801.393	705.305	110.4399	57.23676	28.60414	0	9.973991
Mar-2003	856.909	652.4814	100.0532	55.78647	26.20093	0	9.856574
Apr-2003	1117.517	784.6971	114.2265	59.3122	31.30594	0	10.81051
May-2003	1166.422	1005.642	137.368	62.93727	30.09102	0	13.41527
Jun-2003	1098.597	864.0363	136.6502	69.594	36.99426	0	18.31656
Jul-2003	1141.412	895.0125	133.5098	68.91183	39.13986	0	22.55466
Aug-2003	1971.776	1710.688	195.8134	72.92246	39.64606	0	21.73639
Sep-2003	1112.783	995.7909	128.272	67.46624	41.56743	0	26.25451
Oct-2003	1176.122	1162.422	156.4244	87.82876	65.55117	0	47.17034
Nov-2003	1615.426	2284.043	328.8099	151.2312	112.9519	0	51.62101
Dec-2003	1174.524	1035.554	82.2348	46.61107	32.70178	0	6.434213
...	...	...	...	...	...	...	...
Jan-2016	1058.769	846.8375	51.95852	37.99749	20.34077	7.881876	0.208696
Feb-2016	2151.961	1468.131	32.79796	20.42282	13.16401	7.102694	0.216053
Mar-2016	2760.612	1650.108	32.22614	23.89181	15.28271	8.345982	0.619022
Apr-2016	3350.835	2047.217	53.37524	43.16537	25.62661	13.69089	0.341476
May-2016	4409.263	2560.089	237.1837	135.0017	190.1391	92.89568	0.725926
Jun-2016	10027.91	5295.683	882.2911	712.6334	818.8728	361.0151	0.603599
Jul-2016	2234.278	1179.607	4.70768	7.63762	8.00614	2.837924	0.155484
Aug-2016	2228.604	1453.346	3.52342	4.38228	2.7084	1.22399	0.126319
Sep-2016	4055.024	2136.972	5.2807	5.46725	3.7406	1.8023	0.123196
Oct-2016	3225.003	1600.652	13.14292	13.95552	6.24787	2.779352	0.34031
Nov-2016	3671.191	2040.496	19.06444	15.40349	7.83919	3.156502	0.263397
Dec-2016	5863.699	2959.721	69.72516	60.33594	25.90522	10.85892	1.358788

### Lampiran 3 Syntax Program SAS untuk Metode ARIMA

```

data datal;
input x;
datalines;
1448.39
931.61
936.40
1072.51
1088.48
1115.94
1302.41
1489.97
1228.78
1342.87
554.85
2286.18
1338.32
978.20
1039.72
1118.86
1049.21
1081.05
.
.
2829.65
2519.42
2408.29
2872.51
2761.45
7186.92
3453.89
2157.36
2904.81
2685.34
2086.62
;
proc arima data=datall;
identify var=x(1);
estimate p=6 q=(12,23) noconstant method=cls;
forecast out=ramalan lead=12;
outlier maxnum=5;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;

```

## Lampiran 4 Syntax Program SAS untuk model *Time Series Regression Outflow* Pecahan Rp100.000,00

```

data outflow;
input y t D2 D3 tD2 tD3 M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 L1 L2 L3 L4 L1t2 L2t2 L3t2 L4t2;
datalines;
6.616768418 1 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
6.686351463 2 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
6.753331729 3 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
7.018864181 4 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
7.061696051 5 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0
7.001788917 6 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0
7.040021021 7 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0
7.586689938 8 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0
7.014619454 9 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0
7.069977795 10 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 1
7.387354226 11 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 1 0 0 0
7.068618153 12 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0
.
.
.
8.95649801 151 0 1 0 151 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 1 0 0 0 0
7.567382128 152 0 1 0 152 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0
8.187827253 153 0 1 0 153 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0
7.797194761 154 0 1 0 154 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0
7.942028849 155 0 1 0 155 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0
8.573905757 156 0 1 0 156 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0
.
. 157 0 1 0 157 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
. 158 0 1 0 158 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
. 159 0 1 0 159 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
. 160 0 1 0 160 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
. 161 0 1 0 161 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0
. 162 0 1 0 162 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 1 0 0
. 163 0 1 0 163 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0
. 164 0 1 0 164 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0
. 165 0 1 0 165 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0
. 166 0 1 0 166 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0
. 167 0 1 0 167 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0
. 168 0 1 0 168 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0
;
proc arima data =outflow;
  identify var=y crosscorr=(t D2 D3 tD3 M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 L1 L2 L3 L4 L1t2
L2t2) nlag=24;
  run;
  estimate input=(t D2 D3 tD3 M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 L1 L2 L3 L4 L1t2 L2t2)
noconstant method=cls;
  forecast out = outflow lead=12 printall;
  run;
proc univariate data=outflow normal;
  var residual;
  run;



proc export data=work.outflow
  outfile='D:\TSR_OUT100_selectback_trans.xls'
  dbms=excel
  replace;
  run;

```





## Lampiran 6 Plot ACF dan PACF Dekomposisi (*Time Series Regression*) Data *Outflow* Per Pecahan



a. Pecahan Rp100.000,00



b. Pecahan Rp50.000,00




c. Pecahan Rp20.000,00




**Lampiran 6** (Lanjutan) Plot ACF dan PACF Dekomposisi (*Time Series Regression*) Data *Outflow* Per Pecahan


d. Pecahan Rp10.000,00



e. Pecahan Rp5.000,00




f. Pecahan Rp2.000,00



**Lampiran 6** (Lanjutan) Plot ACF dan PACF Dekomposisi (*Time Series Regression*) Data *Outflow* Per Pecahan



g. Pecahan Rp1.000,00







## Lampiran 7 Plot ACF dan PACF Dekomposisi (*Time Series Regression*) Data *Inflow* Per Pecahan



a. Pecahan Rp100.000,00



b. Pecahan Rp50.000,00





c. Pecahan Rp20.000,00





**Lampiran 7** (Lanjutan) Plot ACF dan PACF Dekomposisi (*Time Series Regression*) Data *Inflow* Per Pecahan



d. Pecahan Rp10.000,00



e. Pecahan Rp5.000,00




f. Pecahan Rp2.000,00



**Lampiran 7** (Lanjutan) Plot ACF dan PACF Dekomposisi (*Time Series Regression*) Data *Inflow* Per Pecahan

g. Pecahan Rp1.000,00



## Lampiran 8 Output Program SAS untuk model *Time Series Regression Outflow* Pecahan Rp100.000,00

2017 277		The SAS System				10:42 Thursday, May 20,			
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Error	Standard t Value	Pr >  t	Approx Lag	Variable	Shift		
NUM1	0.0083242	0.0023742	3.51	0.0006	0	t		0	
NUM2	-0.99618	0.13125	-7.59	<.0001	0	D2		0	
NUM3	-1.38339	0.31087	-4.45	<.0001	0	D3		0	
NUM4	0.0073896	0.0033188	2.23	0.0276	0	tD3		0	
NUM5	6.03646	0.10797	55.91	<.0001	0	M1		0	
NUM6	6.43951	0.10863	59.28	<.0001	0	M2		0	
NUM7	6.87365	0.10931	62.88	<.0001	0	M3		0	
NUM8	6.92935	0.11002	62.98	<.0001	0	M4		0	
NUM9	6.86956	0.11075	62.03	<.0001	0	M5		0	
NUM10	7.23355	0.11150	64.87	<.0001	0	M6		0	
NUM11	7.01542	0.11456	61.24	<.0001	0	M7		0	
NUM12	6.88808	0.11635	59.20	<.0001	0	M8		0	
NUM13	6.91245	0.11787	58.65	<.0001	0	M9		0	
NUM14	6.76580	0.12138	55.74	<.0001	0	M10		0	
NUM15	6.74843	0.11918	56.62	<.0001	0	M11		0	
NUM16	7.40372	0.11647	63.57	<.0001	0	M12		0	
NUM17	-0.62445	0.23500	-2.66	0.0088	0	L1		0	
NUM18	0.46591	0.16657	2.80	0.0059	0	L2		0	
NUM19	0.96448	0.19224	5.02	<.0001	0	L3		0	
NUM20	0.90150	0.16686	5.40	<.0001	0	L4		0	
NUM21	1.23744	0.23517	5.26	<.0001	0	L1t2		0	
NUM22	0.73286	0.16655	4.40	<.0001	0	L2t2		0	
Variance Estimate					0.099678				
Std Error Estimate					0.315718				
AIC					103.2874				
SBC					170.3843				
Number of Residuals					156				
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.92	6	0.6878	-0.087	0.039	0.049	-0.004	-0.044	0.104
12	14.83	12	0.2510	0.032	-0.056	-0.152	-0.036	-0.094	0.164
18	28.60	18	0.0535	-0.183	-0.111	-0.112	-0.116	-0.047	0.070
24	32.62	24	0.1124	-0.015	-0.023	0.031	-0.065	0.047	0.116
30	37.81	30	0.1546	0.125	-0.071	0.048	0.049	0.043	-0.004
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.988348	Pr < W	0.2213				
Kolmogorov-Smirnov		D	0.055808	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.090961	Pr > W-Sq	0.1490				
Anderson-Darling		A-Sq	0.512399	Pr > A-Sq	0.2006				

## Lampiran 9 Output Program SAS untuk model *Time Series Regression Outflow Pecahan Rp50.000,00*

2017 1058		The SAS System				19:03 Thursday, May 20,			
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
NUM1	-0.98989	0.08346	-11.86	<.0001	0	D2		0	
NUM2	-1.67100	0.36267	-4.61	<.0001	0	D3		0	
NUM3	0.01295	0.0027912	4.64	<.0001	0	tD3		0	
NUM4	7.95868	0.44380	17.93	<.0001	0	M1		0	
NUM5	8.16302	0.37191	21.95	<.0001	0	M2		0	
NUM6	8.64523	0.39376	21.96	<.0001	0	M3		0	
NUM7	8.76898	0.41194	21.29	<.0001	0	M4		0	
NUM8	8.66006	0.41391	20.92	<.0001	0	M5		0	
NUM9	8.97904	0.41068	21.86	<.0001	0	M6		0	
NUM10	8.87389	0.42721	20.77	<.0001	0	M7		0	
NUM11	8.72880	0.42707	20.44	<.0001	0	M8		0	
NUM12	8.70899	0.43669	19.94	<.0001	0	M9		0	
NUM13	8.67010	0.43035	20.15	<.0001	0	M10		0	
NUM14	8.62587	0.42314	20.39	<.0001	0	M11		0	
NUM15	9.24399	0.41050	22.52	<.0001	0	M12		0	
NUM16	-0.70557	0.25849	-2.73	0.0073	0	L1		0	
NUM17	0.97894	0.18326	5.34	<.0001	0	L2		0	
NUM18	1.16267	0.21150	5.50	<.0001	0	L3		0	
NUM19	1.02708	0.21184	4.85	<.0001	0	L4		0	
NUM20	1.28166	0.26053	4.92	<.0001	0	L1t2		0	
NUM21	0.64487	0.18348	3.51	0.0006	0	L2t2		0	
NUM22	-0.21530	0.05613	-3.84	0.0002	0	lag13		0	
Variance Estimate				0.119457					
Std Error Estimate				0.345626					
AIC				122.0818					
SBC				187.2644					
Number of Residuals				143					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
0.013	6	8.28	6 0.2181	0.062	0.190	0.000	0.067	-0.107	-
0.144	12	13.72	12 0.3187	-0.004	0.053	-0.099	0.036	0.011	-
0.099	18	26.27	18 0.0937	0.026	-0.107	-0.105	-0.070	-0.196	-
0.041	24	29.30	24 0.2089	-0.012	-0.072	-0.054	-0.046	0.076	-
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.973626	Pr < W	0.0073				
Kolmogorov-Smirnov		D	0.070361	Pr > D	0.0824				
Cramer-von Mises		W-Sq	0.078448	Pr > W-Sq	0.2222				
Anderson-Darling		A-Sq	0.648642	Pr > A-Sq	0.0913				

## Lampiran 10 Output Program SAS untuk model *Time Series Regression Outflow* Pecahan Rp20.000,00

2017 243		The SAS System				19:03 Thursday, May 20,			
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
NUM1	-73.37785	9.11039	-8.05	<.0001	0	D2		0	
NUM2	-62.36225	8.62167	-7.23	<.0001	0	D3		0	
NUM3	99.55416	13.29269	7.49	<.0001	0	M1		0	
NUM4	103.61348	13.29269	7.79	<.0001	0	M2		0	
NUM5	107.82599	13.29269	8.11	<.0001	0	M3		0	
NUM6	117.76154	13.29269	8.86	<.0001	0	M4		0	
NUM7	117.47423	13.29269	8.84	<.0001	0	M5		0	
NUM8	160.55936	13.54958	11.85	<.0001	0	M6		0	
NUM9	167.45679	14.04707	11.92	<.0001	0	M7		0	
NUM10	133.07205	13.98713	9.51	<.0001	0	M8		0	
NUM11	85.37490	14.20209	6.01	<.0001	0	M9		0	
NUM12	63.22969	14.27054	4.43	<.0001	0	M10		0	
NUM13	90.31552	13.57501	6.65	<.0001	0	M11		0	
NUM14	106.65582	13.29269	8.02	<.0001	0	M12		0	
NUM15	65.70991	23.12321	2.84	0.0052	0	L2		0	
NUM16	169.52343	26.79622	6.33	<.0001	0	L3		0	
NUM17	265.59068	23.19318	11.45	<.0001	0	L4		0	
NUM18	185.57166	32.68625	5.68	<.0001	0	L1t2		0	
NUM19	203.89976	23.21823	8.78	<.0001	0	L2t2		0	
NUM20	282.64251	26.69920	10.59	<.0001	0	L3t2		0	
NUM21	80.64002	23.20012	3.48	0.0007	0	L4t2		0	
Variance Estimate				1924.755					
Std Error Estimate				43.87203					
AIC				1641.913					
SBC				1705.96					
Number of Residuals				156					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.74	6	0.8409	-0.022	-0.011	0.091	0.021	0.058	
12	8.11	12	0.7762	0.021	0.026	-0.031	-0.113	0.108	-
18	14.15	18	0.7191	-0.116	-0.127	-0.011	-0.067	-0.021	-
24	19.54	24	0.7225	-0.050	-0.070	-0.010	-0.133	0.026	-
30	20.91	30	0.8907	-0.077	0.007	0.033	-0.001	-0.006	-
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.855763	Pr < W	<0.0001				
Kolmogorov-Smirnov		D	0.143375	Pr > D	<0.0100				
Cramer-von Mises		W-Sq	1.05588	Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	5.981027	Pr > A-Sq	<0.0050				

## Lampiran 11 Output Program SAS untuk model Time Series Regression Outflow Pecahan Rp10.000,00

2017 784		The SAS System				19:03 Thursday, May 20,			
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
NUM1	-0.31564	0.10403	-3.03	0.0030	0	D3		0	
NUM2	-0.0046104	0.0013809	-3.34	0.0011	0	tD2		0	
NUM3	1.64308	0.33521	4.90	<.0001	0	M1		0	
NUM4	1.63976	0.34421	4.75	<.0001	0	M2		0	
NUM5	1.69047	0.35639	4.74	<.0001	0	M3		0	
NUM6	2.04494	0.36260	5.64	<.0001	0	M4		0	
NUM7	1.81369	0.38558	4.70	<.0001	0	M5		0	
NUM8	2.01729	0.39754	5.07	<.0001	0	M6		0	
NUM9	2.04086	0.39253	5.20	<.0001	0	M7		0	
NUM10	1.79287	0.37049	4.84	<.0001	0	M8		0	
NUM11	1.27755	0.34797	3.67	0.0004	0	M9		0	
NUM12	1.14548	0.30746	3.73	0.0003	0	M10		0	
NUM13	1.24339	0.32160	3.87	0.0002	0	M11		0	
NUM14	1.87980	0.31828	5.91	<.0001	0	M12		0	
NUM15	1.26644	0.24396	5.19	<.0001	0	L2		0	
NUM16	2.68161	0.28641	9.36	<.0001	0	L3		0	
NUM17	1.98924	0.27000	7.37	<.0001	0	L4		0	
NUM18	1.26945	0.32767	3.87	0.0002	0	L1t2		0	
NUM19	1.27912	0.24759	5.17	<.0001	0	L2t2		0	
NUM20	0.74117	0.28086	2.64	0.0094	0	L3t2		0	
NUM21	0.28862	0.06540	4.41	<.0001	0	lag1		0	
NUM22	0.53857	0.05748	9.37	<.0001	0	lag11		0	
NUM23	-0.28185	0.06274	-4.49	<.0001	0	lag13		0	
Variance Estimate				0.180472					
Std Error Estimate				0.42482					
AIC				181.8991					
SBC				250.0445					
Number of Residuals				143					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
	To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----				
-	6	5.07	6	0.5351	0.038	0.077	0.126	0.029	-0.099
0.015	12	21.92	12	0.0385	-0.062	-0.097	-0.124	-0.056	-0.269
0.059	18	25.55	18	0.1105	0.014	-0.053	-0.114	-0.021	-0.070
0.033	24	28.98	24	0.2209	-0.038	-0.033	0.067	0.089	0.027
0.066									
Tests for Normality									
	Test	--Statistic--			-----p Value-----				
	Shapiro-Wilk	W	0.990854		Pr < W	0.4808			
	Kolmogorov-Smirnov	D	0.055491		Pr > D	>0.1500			
	Cramer-von Mises	W-Sq	0.074706		Pr > W-Sq	0.2443			
	Anderson-Darling	A-Sq	0.404659		Pr > A-Sq	>0.2500			

## Lampiran 12 Output Program SAS untuk model *Time Series Regression Outflow* Pecahan Rp5.000,00

15		The SAS System		09:57 Sunday, May 30, 2017		
The ARIMA Procedure						
Conditional Least Squares Estimation						
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable Shift
NUM1	22.71785	11.85852	1.92	0.0577	0	M6 0
NUM2	29.43175	11.75592	2.50	0.0136	0	M8 0
NUM3	98.94446	30.81592	3.21	0.0017	0	L3 0
NUM4	65.89787	29.48175	2.24	0.0272	0	L4 0
NUM5	66.89191	24.63386	2.72	0.0076	0	L1t2 0
NUM6	110.54915	22.96152	4.81	<.0001	0	L2t2 0
NUM7	-0.08101	0.04048	-2.00	0.0476	0	lag1 0
NUM8	-0.07719	0.03459	-2.23	0.0274	0	lag10 0
NUM9	0.37961	0.08983	4.23	<.0001	0	lag12 0
NUM10	0.68799	0.05872	11.72	<.0001	0	lag23 0
Variance Estimate				1137.968		
Std Error Estimate				33.73378		
AIC				1322.963		
SBC				1351.866		
Number of Residuals				133		
* AIC and SBC do not include log determinant.						
Autocorrelation Check of Residuals						
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----		
-	6	5.92	6 0.4317	0.201	-0.033	0.008 0.031 0.006
0.030	12	7.68	12 0.8099	0.025	0.065	0.011 -0.034 -0.004 -
0.077	18	10.18	18 0.9260	0.118	0.016	-0.012 -0.003 -0.007 -
0.047	24	21.98	24 0.5807	-0.038	-0.026	0.038 -0.143 -0.212 -
0.059						
Tests for Normality						
Test	--Statistic--		-----p Value-----			
Shapiro-Wilk	W	0.811042	Pr < W	<0.0001		
Kolmogorov-Smirnov	D	0.177395	Pr > D	<0.0100		
Cramer-von Mises	W-Sq	1.164116	Pr > W-Sq	<0.0050		
Anderson-Darling	A-Sq	6.861216	Pr > A-Sq	<0.0050		



## Lampiran 13 Output Program SAS untuk model *Time Series Regression Outflow Pecahan Rp2.000,00*

2017 185		The SAS System				10:38 Friday, May 21,			
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
NUM1	0.52345	0.07194	7.28	<.0001	0	D3			0
NUM2	-0.20329	0.08876	-2.29	0.0265	0	M2			0
NUM3	-0.32558	0.15195	-2.14	0.0374	0	M7			0
NUM4	-0.57872	0.15517	-3.73	0.0005	0	M8			0
NUM5	-0.41118	0.13461	-3.05	0.0037	0	M9			0
NUM6	-0.53988	0.10029	-5.38	<.0001	0	M10			0
NUM7	-0.24186	0.08576	-2.82	0.0070	0	M11			0
NUM8	1.06705	0.17037	6.26	<.0001	0	L2			0
NUM9	1.49692	0.16962	8.83	<.0001	0	L3			0
NUM10	1.18444	0.18180	6.52	<.0001	0	L4			0
NUM11	0.89545	0.24647	3.59	0.0008	0	L2t2			0
NUM12	0.57692	0.16746	3.45	0.0012	0	L3t2			0
NUM13	0.40764	0.16684	2.44	0.0184	0	L4t2			0
NUM14	0.27410	0.07356	3.73	0.0005	0	lag1			0
NUM15	0.16417	0.06587	2.49	0.0163	0	lag2			0
NUM16	0.43160	0.06628	6.51	<.0001	0	lag11			0
NUM17	-0.25038	0.07437	-3.37	0.0015	0	lag13			0
Variance Estimate				0.032873					
Std Error Estimate				0.181308					
AIC				-22.7023					
SBC				13.9987					
Number of Residuals				64					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.53	6	0.3663	0.141	0.054	-0.081	-0.029	-0.008	-
12	10.79	12	0.5472	-0.123	-0.128	-0.006	-0.079	-0.099	-
18	11.60	18	0.8671	0.020	0.093	0.003	0.021	-0.014	
24	17.61	24	0.8215	0.157	0.136	0.104	-0.010	-0.077	-
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.983318	Pr < W	0.5396					
Kolmogorov-Smirnov	D	0.053863	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.034856	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.274073	Pr > A-Sq	>0.2500					

## Lampiran 14 Output Program SAS untuk model *Time Series Regression Outflow* Pecahan Rp1.000,00

393	The SAS System				06:59 Friday, May 21, 2017			
The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift	
NUM1	-0.0079171	0.0039822	-1.99	0.0494	0	t		0
NUM2	1.92506	0.39217	4.91	<.0001	0	D2		0
NUM3	-1.40311	0.32084	-4.37	<.0001	0	D3		0
NUM4	-0.03224	0.0063749	-5.06	<.0001	0	tD2		0
NUM5	2.12099	0.36776	5.77	<.0001	0	M1		0
NUM6	2.15179	0.37382	5.76	<.0001	0	M2		0
NUM7	2.21135	0.37381	5.92	<.0001	0	M3		0
NUM8	2.18235	0.37164	5.87	<.0001	0	M4		0
NUM9	2.02856	0.37482	5.41	<.0001	0	M5		0
NUM10	2.03305	0.39740	5.12	<.0001	0	M6		0
NUM11	1.97063	0.42469	4.64	<.0001	0	M7		0
NUM12	2.51319	0.42287	5.94	<.0001	0	M8		0
NUM13	1.71231	0.40615	4.22	<.0001	0	M9		0
NUM14	1.72891	0.37521	4.61	<.0001	0	M10		0
NUM15	1.73933	0.37633	4.62	<.0001	0	M11		0
NUM16	2.17583	0.37610	5.79	<.0001	0	M12		0
NUM17	1.59176	0.29209	5.45	<.0001	0	L2		0
NUM18	1.88976	0.30787	6.14	<.0001	0	L3		0
NUM19	2.42133	0.29680	8.16	<.0001	0	L4		0
NUM20	1.69224	0.34606	4.89	<.0001	0	L1t2		0
NUM21	1.88284	0.28961	6.50	<.0001	0	L2t2		0
NUM22	1.04762	0.25928	4.04	0.0001	0	L4t2		0
NUM23	0.33869	0.06754	5.01	<.0001	0	lag1		0
NUM24	-0.19011	0.05589	-3.40	0.0009	0	lag13		0
NUM25	0.26277	0.06896	3.81	0.0002	0	lag23		0
NUM26	-0.17110	0.07782	-2.20	0.0301	0	lag24		0
				Variance Estimate	0.170259			
				Std Error Estimate	0.412624			
				AIC	163.9464			
				SBC	238.8993			
				Number of Residuals	132			
* AIC and SBC do not include log determinant.								
Autocorrelation Check of Residuals								
-	To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----			
0.060	6	9.70	6	0.1377	0.220	0.119	-0.058	0.006
0.027	12	12.16	12	0.4326	-0.056	-0.056	-0.049	-0.087
0.181	18	20.02	18	0.3316	-0.056	-0.056	-0.046	0.021
0.086	24	29.50	24	0.2020	-0.088	-0.068	-0.030	-0.047
Tests for Normality								
Test		--Statistic--		-----p Value-----				
Shapiro-Wilk		W	0.993224	Pr < W	0.7827			
Kolmogorov-Smirnov		D	0.050908	Pr > D	>0.1500			
Cramer-von Mises		W-Sq	0.046511	Pr > W-Sq	>0.2500			
Anderson-Darling		A-Sq	0.288586	Pr > A-Sq	>0.2500			

## Lampiran 15 Output Program SAS untuk model *Time Series Regression Inflow Pecahan Rp100.000,00*

The SAS System				18:15 Friday, May 28, 2017 365					
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
NUM1	0.0091974	0.0015998	5.75	<.0001	0	t	0		
NUM2	-0.87697	0.10450	-8.39	<.0001	0	D2	0		
NUM3	-0.48465	0.15992	-3.03	0.0029	0	D3	0		
NUM4	6.08002	0.40163	15.14	<.0001	0	M1	0		
NUM5	5.56311	0.38432	14.48	<.0001	0	M2	0		
NUM6	5.42646	0.36772	14.76	<.0001	0	M3	0		
NUM7	5.30151	0.41429	12.80	<.0001	0	M4	0		
NUM8	5.46271	0.38388	14.23	<.0001	0	M5	0		
NUM9	5.34658	0.37425	14.29	<.0001	0	M6	0		
NUM10	5.52656	0.37724	14.65	<.0001	0	M7	0		
NUM11	5.49355	0.38092	14.42	<.0001	0	M8	0		
NUM12	5.38935	0.37359	14.43	<.0001	0	M9	0		
NUM13	5.60578	0.38413	14.59	<.0001	0	M10	0		
NUM14	5.22155	0.39495	13.22	<.0001	0	M11	0		
NUM15	5.06310	0.38896	13.02	<.0001	0	M12	0		
NUM16	1.17715	0.19758	5.96	<.0001	0	L1	0		
NUM17	1.05732	0.13996	7.55	<.0001	0	L2	0		
NUM18	0.44126	0.16154	2.73	0.0072	0	L3	0		
NUM19	-0.44804	0.13990	-3.20	0.0017	0	L4	0		
NUM20	0.34791	0.13961	2.49	0.0140	0	L2t1	0		
NUM21	0.58297	0.16185	3.60	0.0004	0	L3t1	0		
NUM22	1.10815	0.13989	7.92	<.0001	0	L4t1	0		
NUM23	0.19257	0.05484	3.51	0.0006	0	lag3	0		
Variance Estimate				0.069885					
Std Error Estimate				0.264358					
AIC				48.15261					
SBC				117.8527					
Number of Residuals				153					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.36	6	0.7620	-0.018	0.096	0.097	-0.047	0.016	-0.000
12	5.83	12	0.9243	-0.097	-0.049	0.017	0.006	-0.053	-0.000
18	12.89	18	0.7982	-0.006	-0.068	-0.081	-0.062	-0.043	-0.154
24	20.24	24	0.6829	-0.105	-0.081	0.049	0.065	0.086	-0.096
30	30.12	30	0.4593	0.119	0.040	0.051	0.165	-0.036	0.075
Tests for Normality									
Test				--Statistic--		-----p Value-----			
Shapiro-Wilk				W	0.966052	Pr < W	0.0008		
Kolmogorov-Smirnov				D	0.09238	Pr > D	<0.0100		
Cramer-von Mises				W-Sq	0.291562	Pr > W-Sq	<0.0050		
Anderson-Darling				A-Sq	1.662319	Pr > A-Sq	<0.0050		

## Lampiran 16 Output Program SAS untuk model *Time Series Regression Inflow Pecahan Rp50.000,00*

332	The SAS System				19:46 Friday, May 28, 2017					
The ARIMA Procedure										
Conditional Least Squares Estimation										
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift			
NUM1	-0.97781	0.18478	-5.29	<.0001	0	D2		0		
NUM2	-0.73048	0.23363	-3.13	0.0022	0	D3		0		
NUM3	0.0067340	0.0023981	2.81	0.0058	0	tD2		0		
NUM4	0.0063351	0.0018225	3.48	0.0007	0	tD3		0		
NUM5	5.94985	0.41435	14.36	<.0001	0	M1		0		
NUM6	5.59193	0.40079	13.95	<.0001	0	M2		0		
NUM7	5.46074	0.38577	14.16	<.0001	0	M3		0		
NUM8	5.35426	0.41845	12.80	<.0001	0	M4		0		
NUM9	5.44692	0.39643	13.74	<.0001	0	M5		0		
NUM10	5.36175	0.38665	13.87	<.0001	0	M6		0		
NUM11	5.50843	0.39138	14.07	<.0001	0	M7		0		
NUM12	5.50289	0.39097	14.07	<.0001	0	M8		0		
NUM13	5.46759	0.38400	14.24	<.0001	0	M9		0		
NUM14	5.64824	0.39175	14.42	<.0001	0	M10		0		
NUM15	5.34736	0.40190	13.31	<.0001	0	M11		0		
NUM16	5.19013	0.40021	12.97	<.0001	0	M12		0		
NUM17	1.07287	0.16905	6.35	<.0001	0	L1		0		
NUM18	0.84954	0.11977	7.09	<.0001	0	L2		0		
NUM19	-0.37851	0.11993	-3.16	0.0020	0	L4		0		
NUM20	0.33341	0.11942	2.79	0.0060	0	L2t1		0		
NUM21	0.61614	0.13846	4.45	<.0001	0	L3t1		0		
NUM22	0.91518	0.11997	7.63	<.0001	0	L4t1		0		
NUM23	0.24657	0.05314	4.64	<.0001	0	lag3		0		
Autocorrelation Check of Residuals										
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
-	6	5.78	6	0.4477	-0.007	0.094	0.099	-0.130	-0.012	-
0.031	12	10.14	12	0.6033	-0.136	-0.008	0.053	0.053	-0.048	
0.014	18	12.68	18	0.8100	-0.009	-0.090	-0.015	-0.023	0.044	-
0.062	24	19.44	24	0.7280	-0.087	-0.038	-0.015	-0.039	0.015	-
0.162	30	25.01	30	0.7244	0.097	0.004	-0.027	0.094	-0.103	-
0.004										
Tests for Normality										
Test	--Statistic--		-----p Value-----							
Shapiro-Wilk	W	0.985336	Pr < W	0.1054						
Kolmogorov-Smirnov	D	0.052199	Pr > D	>0.1500						
Cramer-von Mises	W-Sq	0.079665	Pr > W-Sq	0.2151						
Anderson-Darling	A-Sq	0.594652	Pr > A-Sq	0.1238						

## Lampiran 17 Output Program SAS untuk model *Time Series Regression Inflow Pecahan Rp20.000,00*

585	The SAS System				19:46 Friday, May 28, 2017				
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
NUM1	-0.97257	0.18477	-5.26	<.0001	0	D2		0	
NUM2	0.01158	0.0023698	4.89	<.0001	0	tD2		0	
NUM3	0.28311	0.06772	4.18	<.0001	0	M1		0	
NUM4	-0.20361	0.06862	-2.97	0.0036	0	M7		0	
NUM5	-0.35152	0.06687	-5.26	<.0001	0	M12		0	
NUM6	-0.52805	0.12962	-4.07	<.0001	0	L4		0	
NUM7	0.38348	0.15272	2.51	0.0134	0	L1t1		0	
NUM8	0.32343	0.11021	2.93	0.0040	0	L2t1		0	
NUM9	0.66903	0.13248	5.05	<.0001	0	L3t1		0	
NUM10	0.81965	0.13946	5.88	<.0001	0	L4t1		0	
NUM11	0.40037	0.04130	9.70	<.0001	0	lag1		0	
NUM12	0.22568	0.06759	3.34	0.0011	0	lag11		0	
NUM13	0.36562	0.07324	4.99	<.0001	0	lag23		0	
Variance Estimate				0.044051					
Std Error Estimate				0.209883					
AIC				-25.5229					
SBC				12.05159					
Number of Residuals				133					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
-	6	10.10	6	0.1205	-0.006	0.066	0.146	0.203	0.045
0.062	12	14.50	12	0.2699	0.003	0.043	0.152	-0.074	0.004
0.006	18	21.10	18	0.2743	0.009	-0.147	0.064	-0.037	-0.127 -
0.009	24	34.16	24	0.0819	-0.160	0.001	-0.144	-0.074	-0.156 -
0.073									
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.980316	Pr < W	0.0510				
Kolmogorov-Smirnov		D	0.073231	Pr > D	0.0801				
Cramer-von Mises		W-Sq	0.144314	Pr > W-Sq	0.0286				
Anderson-Darling		A-Sq	0.813631	Pr > A-Sq	0.0363				

## Lampiran 18 Output Program SAS untuk model *Time Series Regression Inflow Pecahan Rp10.000,00*

270		The SAS System			04:51 Saturday, May 29, 2017			
The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift	
NUM1	-0.0065827	0.0034193	-1.93	0.0567	0	t		0
NUM2	0.0049216	0.0022270	2.21	0.0291	0	tD2		0
NUM3	0.0062856	0.0026884	2.34	0.0211	0	tD3		0
NUM4	0.34675	0.07571	4.58	<.0001	0	M1		0
NUM5	0.15108	0.07175	2.11	0.0374	0	M5		0
NUM6	0.15952	0.08040	1.98	0.0496	0	M8		0
NUM7	0.14999	0.07635	1.96	0.0519	0	M9		0
NUM8	0.51349	0.18325	2.80	0.0060	0	L1		0
NUM9	0.25735	0.16419	1.57	0.1198	0	L2		0
NUM10	-0.26403	0.16687	-1.58	0.1163	0	L3		0
NUM11	-0.42675	0.14227	-3.00	0.0033	0	L4		0
NUM12	0.31079	0.16384	1.90	0.0604	0	L1t1		0
NUM13	0.55248	0.12727	4.34	<.0001	0	L2t1		0
NUM14	0.95708	0.17054	5.61	<.0001	0	L3t1		0
NUM15	1.10619	0.16855	6.56	<.0001	0	L4t1		0
NUM16	0.58308	0.06149	9.48	<.0001	0	lag1		0
NUM17	0.15973	0.07943	2.01	0.0467	0	lag11		0
NUM18	0.24927	0.08302	3.00	0.0033	0	lag23		0
Variance Estimate				0.050116				
Std Error Estimate				0.223866				
AIC				-4.02743				
SBC				47.99886				
Number of Residuals				133				
* AIC and SBC do not include log determinant.								
Autocorrelation Check of Residuals								
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----				
6	11.16	6	0.0835	-0.163	0.065	0.099	0.135	0.041
12	14.97	12	0.2432	-0.009	0.054	0.140	0.012	0.026
18	16.77	18	0.5386	-0.043	-0.001	-0.020	-0.032	-0.086
24	25.17	24	0.3963	-0.097	-0.081	-0.137	-0.017	-0.077
Tests for Normality								
Test	--Statistic--		-----p Value-----					
Shapiro-Wilk	W	0.963292	Pr < W	0.0012				
Kolmogorov-Smirnov	D	0.047072	Pr > D	>0.1500				
Cramer-von Mises	W-Sq	0.047673	Pr > W-Sq	>0.2500				
Anderson-Darling	A-Sq	0.436271	Pr > A-Sq	>0.2500				

## Lampiran 19 Output Program SAS untuk model *Time Series Regression Inflow Pecahan* Rp5.000,00

847		The SAS System				04:51 Saturday, May 29, 2017			
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
NUM1	-0.0097214	0.0032763	-2.97	0.0036	0	t		0	
NUM2	-0.88915	0.20800	-4.27	<.0001	0	D2		0	
NUM3	-0.62541	0.23985	-2.61	0.0102	0	D3		0	
NUM4	0.01874	0.0041523	4.51	<.0001	0	tD2		0	
NUM5	0.01288	0.0036107	3.57	0.0005	0	tD3		0	
NUM6	-0.18539	0.07221	-2.57	0.0114	0	M12		0	
NUM7	-0.46259	0.15989	-2.89	0.0045	0	L3		0	
NUM8	-0.64021	0.15012	-4.26	<.0001	0	L4		0	
NUM9	0.41620	0.15771	2.64	0.0093	0	L4t1		0	
NUM10	0.15259	0.05039	3.03	0.0030	0	lag1		0	
NUM11	0.47041	0.04940	9.52	<.0001	0	lag11		0	
NUM12	0.45908	0.06840	6.71	<.0001	0	lag12		0	
				Variance Estimate	0.053786				
				Std Error Estimate	0.231917				
				AIC	-0.7515				
				SBC	34.88626				
				Number of Residuals	144				
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
-									
0.062	6	6.17	6	0.4042	0.128	-0.115	-0.048	0.062	0.044
0.222	12	31.86	12	0.0015	-0.074	0.008	0.198	0.031	-0.261
0.009	18	35.78	18	0.0075	0.050	0.017	0.028	-0.098	-0.103
0.028	24	44.18	24	0.0073	-0.005	-0.111	-0.181	-0.022	0.051
Tests for Normality									
Test	--Statistic--			-----p Value-----					
Shapiro-Wilk	W	0.982331		Pr < W	0.0604				
Kolmogorov-Smirnov	D	0.07257		Pr > D	0.0630				
Cramer-von Mises	W-Sq	0.130039		Pr > W-Sq	0.0449				
Anderson-Darling	A-Sq	0.78747		Pr > A-Sq	0.0418				

## Lampiran 20 Output Program SAS untuk model *Time Series Regression Inflow Pecahan Rp2.000,00*

232	The SAS System				14:17 Saturday, May 29, 2017				
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
NUM1	0.26490	0.08002	3.31	0.0018	0	t		0	
NUM2	-287.19509	99.75922	-2.88	0.0060	0	D2		0	
NUM3	17.12877	4.38731	3.90	0.0003	0	D3		0	
NUM4	18.77408	6.21155	3.02	0.0041	0	tD2		0	
NUM5	-7.00436	4.07199	-1.72	0.0921	0	M3		0	
NUM6	-12.44474	4.22556	-2.95	0.0051	0	M4		0	
NUM7	-15.42412	4.53368	-3.40	0.0014	0	M5		0	
NUM8	-17.74760	4.79021	-3.70	0.0006	0	M6		0	
NUM9	-16.30223	4.75366	-3.43	0.0013	0	M7		0	
NUM10	19.64662	5.01545	3.92	0.0003	0	M9		0	
NUM11	17.00559	4.58662	3.71	0.0006	0	M10		0	
NUM12	-19.43419	9.01937	-2.15	0.0365	0	L2		0	
NUM13	-14.83482	6.48107	-2.29	0.0267	0	L3		0	
NUM14	-17.12902	6.43721	-2.66	0.0107	0	L4		0	
NUM15	-13.17048	6.52767	-2.02	0.0495	0	L4t1		0	
NUM16	0.34634	0.08947	3.87	0.0003	0	lag1		0	
NUM17	-0.17453	0.08605	-2.03	0.0483	0	lag14		0	
Variance Estimate				63.57682					
Std Error Estimate				7.973507					
AIC				454.5649					
SBC				490.9981					
Number of Residuals				63					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.50	6	0.8681	-0.139	0.039	-0.086	-0.018	-0.082	-
12	3.98	12	0.9838	-0.041	-0.039	0.032	-0.074	0.084	-
18	9.18	18	0.9555	0.166	-0.088	-0.053	-0.110	-0.089	
24	15.39	24	0.9089	0.125	-0.046	0.083	0.038	-0.015	-
0.041									
0.048									
0.058									
0.188									
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.970376	Pr < W	0.1326				
Kolmogorov-Smirnov		D	0.094264	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.1114	Pr > W-Sq	0.0752				
Anderson-Darling		A-Sq	0.644033	Pr > A-Sq	0.0913				



## Lampiran 21 Output Program SAS untuk model *Time Series Regression Inflow Pecahan* Rp1.000,00

282	The SAS System				06:41 Saturday, May 29, 2017			
The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift	
NUM1	0.0015579	0.0008111	1.92	0.0570	0	t		0
NUM2	-0.38642	0.23188	-1.67	0.0981	0	D3		0
NUM3	0.0014959	0.0020337	0.74	0.4634	0	td3		0
NUM4	-0.17621	0.06753	-2.61	0.0102	0	M8		0
NUM5	-0.17351	0.06921	-2.51	0.0134	0	M9		0
NUM6	-0.13948	0.06900	-2.02	0.0453	0	M11		0
NUM7	0.53825	0.17877	3.01	0.0031	0	L1		0
NUM8	-0.47909	0.13051	-3.67	0.0004	0	L3		0
NUM9	-0.60248	0.12803	-4.71	<.0001	0	L4		0
NUM10	0.44771	0.16453	2.72	0.0074	0	L1t1		0
NUM11	0.61432	0.13554	4.53	<.0001	0	L2t1		0
NUM12	0.33452	0.14911	2.24	0.0266	0	L3t1		0
NUM13	0.58648	0.14839	3.95	0.0001	0	L4t1		0
NUM14	0.69572	0.06638	10.48	<.0001	0	lag1		0
NUM15	0.42845	0.04643	9.23	<.0001	0	lag11		0
NUM16	-0.16354	0.06693	-2.44	0.0159	0	lag13		0
Variance Estimate				0.044158				
Std Error Estimate				0.210138				
AIC				-25.3095				
SBC				22.09604				
Number of Residuals				143				
* AIC and SBC do not include log determinant.								
Autocorrelation Check of Residuals								
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----				
6	9.24	6	0.1605	-0.196	-0.014	0.123	-0.068	0.065
12	15.16	12	0.2325	-0.149	0.074	-0.041	0.068	-0.044
18	20.65	18	0.2976	-0.113	-0.030	0.104	-0.070	0.066
24	25.63	24	0.3723	-0.100	0.027	-0.025	-0.106	-0.079
Tests for Normality								
Test	--Statistic--		-----p Value-----					
Shapiro-Wilk	W	0.99317	Pr < W	0.7297				
Kolmogorov-Smirnov	D	0.030707	Pr > D	>0.1500				
Cramer-von Mises	W-Sq	0.017906	Pr > W-Sq	>0.2500				
Anderson-Darling	A-Sq	0.141551	Pr > A-Sq	>0.2500				

## Lampiran 22 Output Program SAS untuk model ARIMAX Outflow Pecahan Rp100.000,00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
MA1,1	0.274	0.087	3.17	0.002	13	y	0
NUM1	0.008	0.002	3.25	0.001	0	t	0
NUM2	-0.950	0.130	-7.3	0.000	0	D2	0
NUM3	-1.352	0.273	-4.95	0.000	0	D3	0
NUM4	0.008	0.003	2.59	0.011	0	tD3	0
NUM5	6.038	0.104	58.2	0.000	0	M1	0
NUM6	6.450	0.105	61.62	0.000	0	M2	0
NUM7	6.878	0.105	65.34	0.000	0	M3	0
NUM8	6.937	0.106	65.38	0.000	0	M4	0
NUM9	6.875	0.107	64.45	0.000	0	M5	0
NUM10	7.241	0.108	67.35	0.000	0	M6	0
NUM11	7.030	0.111	63.48	0.000	0	M7	0
NUM12	6.923	0.112	61.56	0.000	0	M8	0
NUM13	6.938	0.114	60.61	0.000	0	M9	0
NUM14	6.798	0.117	58.09	0.000	0	M10	0
NUM15	6.768	0.115	58.71	0.000	0	M11	0
NUM16	7.380	0.113	65.36	0.000	0	M12	0
NUM17	-0.614	0.229	-2.69	0.008	0	L1	0
NUM18	0.460	0.163	2.82	0.006	0	L2	0
NUM19	0.897	0.187	4.79	0.000	0	L3	0
NUM20	0.803	0.160	5.01	0.000	0	L4	0
NUM21	1.229	0.229	5.38	0.000	0	L1t2	0
NUM22	0.622	0.164	3.79	0.000	0	L2t2	0
Autocorrelation Check of Residuals							
To Lag	Chi-Square	DF	Pr > ChiSq				
6	4.47	5	0.4838				
12	18.14	11	0.0785				
18	25.81	17	0.0781				
24	32.15	23	0.097				
30	36.81	29	0.1511				
Tests for Normality							
Test	--Statistic--		-----p Value-----				
Kolmogorov-Smirnov	D	0.044889	Pr > D	>0.1500			

## Lampiran 23 Output Program SAS untuk model ARIMAX Outflow Pecahan Rp50.000,00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
AR1,1	0.31929	0.08419	3.79	0.0002	12	y	0
AR1,2	-0.20889	0.0833	-2.51	0.0134	14	y	0
NUM1	0.0088029	0.0018901	4.66	<.0001	0	t	0
NUM2	-1.21646	0.11839	-10.27	<.0001	0	D2	0
NUM3	-0.82822	0.20417	-4.06	<.0001	0	D3	0
NUM4	6.16472	0.14913	41.34	<.0001	0	M1	0
NUM5	6.54843	0.14952	43.8	<.0001	0	M2	0
NUM6	6.86348	0.15111	45.42	<.0001	0	M3	0
NUM7	6.96675	0.15175	45.91	<.0001	0	M4	0
NUM8	6.86974	0.15207	45.17	<.0001	0	M5	0
NUM9	7.0911	0.15273	46.43	<.0001	0	M6	0
NUM10	6.95164	0.15719	44.22	<.0001	0	M7	0
NUM11	6.8758	0.15801	43.52	<.0001	0	M8	0
NUM12	6.80549	0.15776	43.14	<.0001	0	M9	0
NUM13	6.80638	0.16237	41.92	<.0001	0	M10	0
NUM14	6.66528	0.16145	41.28	<.0001	0	M11	0
NUM15	7.33405	0.15666	46.82	<.0001	0	M12	0
NUM16	-0.6999	0.2422	-2.89	0.0045	0	L1	0
NUM17	1.23516	0.1823	6.78	<.0001	0	L2	0
NUM18	1.20133	0.21437	5.6	<.0001	0	L3	0
NUM19	1.11294	0.18471	6.03	<.0001	0	L4	0
NUM20	1.46109	0.25017	5.84	<.0001	0	L1t2	0
NUM21	0.62043	0.17877	3.47	0.0007	0	L2t2	0
Autocorrelation Check of Residuals							
To Lag	Chi-Square	DF	Pr > ChiSq				
6	6.53	4	0.1629				
12	10.4	10	0.4064				
18	20.71	16	0.1901				
24	27.77	22	0.1835				
30	36.3	28	0.1352				
Tests for Normality							
Test	--Statistic---	-----p Value-----					
Kolmogorov-Smirnov	D	0.060018	Pr > D	>0.1500			

## Lampiran 24 Output Program SAS untuk model ARIMAX Outflow Pecahan Rp20.000,00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.31965	0.09509	-3.36	0.001	12	y	0
AR1,1	0.43042	0.08282	5.2	<.0001	1	y	0
NUM1	-2.02328	0.36456	-5.55	<.0001	0	D3	0
NUM2	-0.02769	0.0047861	-5.78	<.0001	0	tD2	0
NUM3	6.25196	0.3962	15.78	<.0001	0	M1	0
NUM4	6.57896	0.40305	16.32	<.0001	0	M2	0
NUM5	6.64614	0.40555	16.39	<.0001	0	M3	0
NUM6	7.03212	0.40648	17.3	<.0001	0	M4	0
NUM7	7.01353	0.40711	17.23	<.0001	0	M5	0
NUM8	7.53806	0.41168	18.31	<.0001	0	M6	0
NUM9	7.54377	0.42306	17.83	<.0001	0	M7	0
NUM10	6.5756	0.42077	15.63	<.0001	0	M8	0
NUM11	5.32556	0.4209	12.65	<.0001	0	M9	0
NUM12	5.15674	0.42473	12.14	<.0001	0	M10	0
NUM13	5.66187	0.4121	13.74	<.0001	0	M11	0
NUM14	6.70659	0.40036	16.75	<.0001	0	M12	0
NUM15	2.56169	0.43588	5.88	<.0001	0	L2	0
NUM16	3.84119	0.53554	7.17	<.0001	0	L3	0
NUM17	3.9682	0.45725	8.68	<.0001	0	L4	0
NUM18	3.52409	0.59696	5.9	<.0001	0	L1t2	0
NUM19	3.79034	0.45973	8.24	<.0001	0	L2t2	0
NUM20	3.16062	0.53313	5.93	<.0001	0	L3t2	0
NUM21	2.13935	0.44114	4.85	<.0001	0	L4t2	0
Autocorrelation Check of Residuals							
To Lag	Chi-Square	DF	Pr > ChiSq				
6	1.39	4	0.8453				
12	7.17	10	0.7093				
18	16.28	16	0.4335				
24	29.86	22	0.1219				
30	32.62	28	0.2499				
Tests for Normality							
Test	--Statistic--	----p Value-----					
Kolmogorov-Smirnov	D	0.070005	Pr > D	0.0609			

## Lampiran 25 Output Program SAS untuk model ARIMAX Outflow Pecahan Rp10.000,00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
MA1,1	-0.40768	0.07455	-5.47	<.0001	1	y	0
MA1,2	-0.59232	0.07995	-7.41	<.0001	23	y	0
AR1,1	0.41377	0.09805	4.22	<.0001	12	y	0
NUM1	-0.0047912	0.0064549	-0.74	0.4593	0	t	0
NUM2	0.54511	0.59818	0.91	0.3639	0	D2	0
NUM3	-0.91844	0.81194	-1.13	0.2601	0	D3	0
NUM4	-0.01368	0.01158	-1.18	0.2396	0	tD2	0
NUM5	0.004895	0.0090912	0.54	0.5912	0	tD3	0
NUM6	4.03719	0.25171	16.04	<.0001	0	M1	0
NUM7	4.03263	0.26371	15.29	<.0001	0	M2	0
NUM8	4.19826	0.26773	15.68	<.0001	0	M3	0
NUM9	4.48267	0.26864	16.69	<.0001	0	M4	0
NUM10	4.52109	0.26959	16.77	<.0001	0	M5	0
NUM11	4.7604	0.27373	17.39	<.0001	0	M6	0
NUM12	4.60058	0.2789	16.5	<.0001	0	M7	0
NUM13	4.06623	0.27841	14.61	<.0001	0	M8	0
NUM14	3.53276	0.27933	12.65	<.0001	0	M9	0
NUM15	3.26633	0.28863	11.32	<.0001	0	M10	0
NUM16	3.41441	0.27728	12.31	<.0001	0	M11	0
NUM17	3.99768	0.25938	15.41	<.0001	0	M12	0
NUM18	-0.14409	0.28993	-0.5	0.6201	0	L1	0
NUM19	1.91217	0.2695	7.1	<.0001	0	L2	0
NUM20	1.92924	0.33773	5.71	<.0001	0	L3	0
NUM21	2.12888	0.27391	7.77	<.0001	0	L4	0
NUM22	1.4199	0.37515	3.78	0.0002	0	L1t2	0
NUM23	1.77315	0.2845	6.23	<.0001	0	L2t2	0
NUM24	1.3083	0.30997	4.22	<.0001	0	L3t2	0
NUM25	0.9466	0.22935	4.13	<.0001	0	L4t2	0
Autocorrelation Check of Residuals							
To Lag	Chi-Square	DF	Pr > ChiSq				
6	4.01	3	0.2599				
12	8.6	9	0.4747				
18	12.03	15	0.6765				
24	17.77	21	0.6635				
30	23.56	27	0.6546				
Tests for Normality							
Test	--Statistic--	-----p Value-----					
Kolmogorov-Smirnov	D	0.048752	Pr > D	>0.1500			

**Lampiran 26** *Output* Program SAS untuk model ARIMAX  
*Outflow* Pecahan Rp5.000,00

The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Pr >  t	Lag	Variable	Shift
MA1,1	-0.43029	0.09192	-4.68	<.0001	11	y	0
MA1,2	-0.33863	0.09503	-3.56	0.0005	23	y	0
AR1,1	0.46677	0.0871	5.36	<.0001	1	y	0
NUM1	0.40651	0.21077	1.93	0.056	0	D2	0
NUM2	-0.22398	0.07819	-2.86	0.0049	0	D3	0
NUM3	-0.0074927	0.0029579	-2.53	0.0125	0	tD2	0
NUM4	1.79267	0.07448	24.07	<.0001	0	M1	0
NUM5	1.81472	0.07472	24.29	<.0001	0	M2	0
NUM6	1.87398	0.07643	24.52	<.0001	0	M3	0
NUM7	1.94492	0.07711	25.22	<.0001	0	M4	0
NUM8	1.97909	0.07706	25.68	<.0001	0	M5	0
NUM9	2.06331	0.07806	26.43	<.0001	0	M6	0
NUM10	1.97673	0.0795	24.86	<.0001	0	M7	0
NUM11	1.84235	0.07963	23.14	<.0001	0	M8	0
NUM12	1.65754	0.07939	20.88	<.0001	0	M9	0
NUM13	1.59082	0.08131	19.57	<.0001	0	M10	0
NUM14	1.66264	0.07854	21.17	<.0001	0	M11	0
NUM15	1.82181	0.07655	23.8	<.0001	0	M12	0
NUM16	0.13618	0.09286	1.47	0.1449	0	L1	0
NUM17	0.37145	0.07602	4.89	<.0001	0	L2	0
NUM18	0.74158	0.08607	8.62	<.0001	0	L3	0
NUM19	0.67946	0.07906	8.59	<.0001	0	L4	0
NUM20	0.58645	0.10673	5.49	<.0001	0	L1t2	0
NUM21	0.51439	0.07978	6.45	<.0001	0	L2t2	0
NUM22	0.37461	0.08592	4.36	<.0001	0	L3t2	0
NUM23	0.29447	0.06893	4.27	<.0001	0	L4t2	0
Autocorrelation Check of Residuals							
To	Chi-Square	DF	Pr >				
Lag	Square	DF	ChiSq				
6	1.99	3	0.5737				
12	10.25	9	0.3309				
18	14.27	15	0.5051				
24	19.43	21	0.5578				
30	28.41	27	0.3901				
Tests for Normality							
Test	--Statistic--	----p Value-----					
Kolmogorov-Smirnov	D	0.057029	Pr > D	>0.1500			

## Lampiran 27 Output Program SAS untuk model ARIMAX Outflow Pecahan Rp2.000,00

2017 1616		The SAS System				07:55 Friday, May 21,			
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
MA1,1	-0.47106	0.12195	-3.86	0.0003	1	y		0	
AR1,1	0.37458	0.14551	2.57	0.0125	11	y		0	
NUM1	1.92259	0.15281	12.58	<.0001	0	D2		0	
NUM2	1.23835	0.06897	17.95	<.0001	0	D3		0	
NUM3	-0.05071	0.01332	-3.81	0.0003	0	tD2		0	
NUM4	0.18460	0.08948	2.06	0.0435	0	M5		0	
NUM5	0.25301	0.09599	2.64	0.0107	0	M6		0	
NUM6	-0.48128	0.09549	-5.04	<.0001	0	M8		0	
NUM7	-0.62695	0.11587	-5.41	<.0001	0	M9		0	
NUM8	-0.66775	0.11410	-5.85	<.0001	0	M10		0	
NUM9	-0.36997	0.08571	-4.32	<.0001	0	M11		0	
NUM10	0.98901	0.17027	5.81	<.0001	0	L2		0	
NUM11	1.06929	0.12823	8.34	<.0001	0	L3		0	
NUM12	1.30628	0.16655	7.84	<.0001	0	L4		0	
NUM13	1.15122	0.17372	6.63	<.0001	0	L2t2		0	
NUM14	0.65682	0.13426	4.89	<.0001	0	L3t2		0	
NUM15	0.58028	0.15534	3.74	0.0004	0	L4t2		0	
Variance Estimate				0.045664					
Std Error Estimate				0.213691					
AIC				-4.34815					
SBC				35.49654					
Number of Residuals				77					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.77	4	0.1484	0.100	0.190	-0.045	-0.018	-0.113	-
12	12.11	10	0.2779	-0.133	-0.074	0.094	-0.155	-0.022	-
18	16.66	16	0.4080	0.111	-0.103	-0.068	-0.112	0.057	-
24	18.01	22	0.7056	-0.077	-0.001	0.067	-0.004	0.018	-
0.144									
0.055									
0.054									
0.042									
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.991478	Pr < W	0.8927				
Kolmogorov-Smirnov		D	0.05178	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.042808	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.271565	Pr > A-Sq	>0.2500				

Lampiran 28 Output Program SAS untuk model ARIMAX  
Outflow Pecahan Rp1.000,00

The SAS System				11:12 Thursday, June 3, 2017 216					
The ARIMA Procedure									
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
AR1_1	0.46551	0.07844	5.93	<.0001	1	y	0		
NUM1	2.72730	0.60324	4.52	<.0001	0	D2	0		
NUM2	-2.85730	0.15714	-18.18	<.0001	0	D3	0		
NUM3	-0.05158	0.0081009	-6.37	<.0001	0	tD2	0		
NUM4	2.50181	0.16719	14.96	<.0001	0	M1	0		
NUM5	2.46066	0.16876	14.58	<.0001	0	M2	0		
NUM6	2.56894	0.16907	15.19	<.0001	0	M3	0		
NUM7	2.54757	0.16912	15.06	<.0001	0	M4	0		
NUM8	2.46612	0.16915	14.58	<.0001	0	M5	0		
NUM9	2.54298	0.17056	14.91	<.0001	0	M6	0		
NUM10	2.58768	0.17426	14.85	<.0001	0	M7	0		
NUM11	2.84353	0.17370	16.37	<.0001	0	M8	0		
NUM12	2.28116	0.17580	12.98	<.0001	0	M9	0		
NUM13	1.95886	0.17719	11.05	<.0001	0	M10	0		
NUM14	1.95320	0.17083	11.43	<.0001	0	M11	0		
NUM15	2.37574	0.16675	14.25	<.0001	0	M12	0		
NUM16	1.81110	0.22454	8.07	<.0001	0	L2	0		
NUM17	1.79113	0.23869	7.50	<.0001	0	L3	0		
NUM18	2.93032	0.22649	12.94	<.0001	0	L4	0		
NUM19	1.72927	0.29383	5.89	<.0001	0	L1t2	0		
NUM20	2.12698	0.22476	9.46	<.0001	0	L2t2	0		
NUM21	1.24331	0.22693	5.48	<.0001	0	L4t2	0		
				Variance Estimate	0.196487				
				Std Error Estimate	0.443269				
				AIC	209.1578				
				SBC	276.2547				
				Number of Residuals	156				
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
-	To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----				
0.101	6	2.09	5	0.8370	0.011	-0.010	-0.021	-0.041	0.015
0.109	12	9.40	11	0.5853	-0.049	-0.025	-0.068	-0.075	0.134
0.047	18	24.14	17	0.1158	-0.274	-0.015	-0.080	0.038	0.003
0.032	24	31.52	23	0.1106	-0.109	-0.109	-0.025	0.013	0.122
0.029	30	42.29	29	0.0529	-0.077	0.158	0.033	0.138	-0.068
Tests for Normality									
		Test	--Statistic--		-----p Value-----				
		Shapiro-Wilk	W	0.969143	Pr < W	0.0014			
		Kolmogorov-Smirnov	D	0.093564	Pr > D	<0.0100			
		Cramer-von Mises	W-Sq	0.229287	Pr > W-Sq	<0.0050			
		Anderson-Darling	A-Sq	1.396231	Pr > A-Sq	<0.0050			



## Lampiran 29 Output Program SAS untuk model ARIMAX Inflow Pecahan Rp100.000,00

2017 289		The SAS System				06:30 Monday, May 31,				
The ARIMA Procedure										
Conditional Least Squares Estimation										
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift			
AR1,1	0.28248	0.08504	3.32	0.0012	3	y		0		
NUM1	0.0081782	0.0024259	3.37	0.0010	0	t		0		
NUM2	-0.89058	0.13473	-6.61	<.0001	0	D2		0		
NUM3	-1.19413	0.33730	-3.54	0.0006	0	D3		0		
NUM4	0.0072607	0.0035603	2.04	0.0434	0	tD3		0		
NUM5	7.50311	0.10110	74.22	<.0001	0	M1		0		
NUM6	6.94001	0.10180	68.17	<.0001	0	M2		0		
NUM7	6.75750	0.10256	65.89	<.0001	0	M3		0		
NUM8	6.79253	0.10377	65.46	<.0001	0	M4		0		
NUM9	6.84640	0.10457	65.47	<.0001	0	M5		0		
NUM10	6.69572	0.10540	63.53	<.0001	0	M6		0		
NUM11	6.88553	0.10677	64.49	<.0001	0	M7		0		
NUM12	6.87549	0.10930	62.90	<.0001	0	M8		0		
NUM13	6.74118	0.11007	61.25	<.0001	0	M9		0		
NUM14	6.99354	0.11115	62.92	<.0001	0	M10		0		
NUM15	6.64714	0.11222	59.23	<.0001	0	M11		0		
NUM16	6.46471	0.11058	58.46	<.0001	0	M12		0		
NUM17	1.09867	0.18552	5.92	<.0001	0	L1		0		
NUM18	0.98293	0.13062	7.53	<.0001	0	L2		0		
NUM19	0.42273	0.15163	2.79	0.0061	0	L3		0		
NUM20	-0.48728	0.13031	-3.74	0.0003	0	L4		0		
NUM21	0.34182	0.13051	2.62	0.0098	0	L2t1		0		
NUM22	0.53520	0.15162	3.53	0.0006	0	L3t1		0		
NUM23	1.08243	0.13026	8.31	<.0001	0	L4t1		0		
Variance Estimate				0.067326						
Std Error Estimate				0.259473						
AIC				43.72848						
SBC				116.925						
Number of Residuals				156						
* AIC and SBC do not include log determinant.										
Autocorrelation Check of Residuals										
	To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
-	6	1.35	5	0.9294	-0.024	0.042	0.009	-0.064	0.012	-
0.042	12	4.76	11	0.9420	-0.114	-0.062	0.034	-0.025	-0.006	
0.042	18	11.40	17	0.8350	-0.064	-0.068	-0.065	-0.078	-0.029	-
0.133	24	19.65	23	0.6629	-0.112	-0.052	0.088	0.042	0.125	-
0.069	30	25.96	29	0.6278	0.045	0.073	0.049	0.139	-0.015	
0.059										
Tests for Normality										
Test		--Statistic--			-----p Value-----					
Shapiro-Wilk		W	0.962797		Pr < W	0.0003				
Kolmogorov-Smirnov		D	0.109482		Pr > D	<0.0100				
Cramer-von Mises		W-Sq	0.382758		Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	2.059649		Pr > A-Sq	<0.0050				

Lampiran 30 Output Program SAS untuk model ARIMAX  
Inflow Pecahan Rp50.000,00

586	The SAS System				06:30 Monday, May 31, 2017					
The ARIMA Procedure										
Conditional Least Squares Estimation										
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift			
AR1_1	0.35376	0.08363	4.23	<.0001	3	y		0		
NUM1	0.0086828	0.0016296	5.33	<.0001	0	t		0		
NUM2	-0.96190	0.10417	-9.23	<.0001	0	D2		0		
NUM3	-0.74180	0.17666	-4.20	<.0001	0	D3		0		
NUM4	7.53965	0.08500	88.70	<.0001	0	M1		0		
NUM5	7.12495	0.08558	83.26	<.0001	0	M2		0		
NUM6	6.93681	0.08625	80.42	<.0001	0	M3		0		
NUM7	7.01073	0.08706	80.53	<.0001	0	M4		0		
NUM8	7.00004	0.08775	79.78	<.0001	0	M5		0		
NUM9	6.86723	0.08848	77.62	<.0001	0	M6		0		
NUM10	7.02976	0.08953	78.52	<.0001	0	M7		0		
NUM11	7.03285	0.09185	76.57	<.0001	0	M8		0		
NUM12	6.96442	0.09233	75.43	<.0001	0	M9		0		
NUM13	7.17798	0.09355	76.73	<.0001	0	M10		0		
NUM14	6.91610	0.09467	73.06	<.0001	0	M11		0		
NUM15	6.73849	0.09291	72.52	<.0001	0	M12		0		
NUM16	0.94928	0.15796	6.01	<.0001	0	L1		0		
NUM17	0.74973	0.11136	6.73	<.0001	0	L2		0		
NUM18	-0.41424	0.11072	-3.74	0.0003	0	L4		0		
NUM19	0.29970	0.11128	2.69	0.0080	0	L2t1		0		
NUM20	0.57004	0.12906	4.42	<.0001	0	L3t1		0		
NUM21	0.89238	0.11059	8.07	<.0001	0	L4t1		0		
Variance Estimate				0.051082						
Std Error Estimate				0.226013						
AIC				-1.00106						
SBC				66.09578						
Number of Residuals				156						
* AIC and SBC do not include log determinant.										
Autocorrelation Check of Residuals										
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
-	6	2.91	5	0.7134	0.037	0.023	0.005	-0.114	-0.007	-
0.055	12	11.16	11	0.4301	-0.160	0.027	0.090	0.072	0.040	
0.090	18	14.58	17	0.6255	-0.014	-0.086	-0.002	-0.081	0.025	-
0.069	24	21.75	23	0.5354	-0.115	0.042	0.049	-0.008	0.075	-
0.126	30	25.62	29	0.6457	0.001	-0.015	-0.049	-0.005	-0.128	-
0.030										
Tests for Normality										
Test	--Statistic--			-----p Value-----						
Shapiro-Wilk	W	0.968566	Pr < W	0.0013						
Kolmogorov-Smirnov	D	0.081517	Pr > D	0.0123						
Cramer-von Mises	W-Sq	0.222254	Pr > W-Sq	<0.0050						
Anderson-Darling	A-Sq	1.359013	Pr > A-Sq	<0.0050						

## Lampiran 31 Output Program SAS untuk model ARIMAX Inflow Pecahan Rp20.000,00

The SAS System				06:30 Monday, May 31, 2017 800			
The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.46850	0.08214	-5.70	<.0001	1	y	0
AR1,1	0.50837	0.09327	5.45	<.0001	11	y	0
NUM1	-0.0074371	0.0039790	-1.87	0.0639	0	t	0
NUM2	-0.60702	0.34560	-1.76	0.0814	0	D2	0
NUM3	-0.91803	0.44293	-2.07	0.0402	0	D3	0
NUM4	0.0035351	0.0065702	0.54	0.5915	0	tD2	0
NUM5	0.0074523	0.0052173	1.43	0.1556	0	tD3	0
NUM6	5.59329	0.13541	41.31	<.0001	0	M1	0
NUM7	5.34216	0.13616	39.24	<.0001	0	M2	0
NUM8	5.14424	0.13680	37.60	<.0001	0	M3	0
NUM9	5.07739	0.13757	36.91	<.0001	0	M4	0
NUM10	5.06051	0.13866	36.50	<.0001	0	M5	0
NUM11	4.93995	0.13995	35.30	<.0001	0	M6	0
NUM12	4.90666	0.14135	34.71	<.0001	0	M7	0
NUM13	5.21362	0.14294	36.47	<.0001	0	M8	0
NUM14	5.28777	0.14321	36.92	<.0001	0	M9	0
NUM15	5.35899	0.14452	37.08	<.0001	0	M10	0
NUM16	5.34921	0.14644	36.53	<.0001	0	M11	0
NUM17	5.20496	0.14277	36.46	<.0001	0	M12	0
NUM18	0.35924	0.16662	2.16	0.0329	0	L1	0
NUM19	0.46197	0.12121	3.81	0.0002	0	L2	0
NUM20	-0.04701	0.13921	-0.34	0.7362	0	L3	0
NUM21	-0.58993	0.11622	-5.08	<.0001	0	L4	0
NUM22	0.44102	0.16052	2.75	0.0069	0	L1t1	0
NUM23	0.39936	0.11790	3.39	0.0009	0	L2t1	0
NUM24	0.45146	0.14396	3.14	0.0021	0	L3t1	0
NUM25	0.73783	0.12172	6.06	<.0001	0	L4t1	0
Variance Estimate				0.056546			
Std Error Estimate				0.237794			
AIC				18.92064			
SBC				101.2668			
Number of Residuals				156			
* AIC and SBC do not include log determinant.							
Autocorrelation Check of Residuals							
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----			
6	1.84	4	0.7651	0.017	0.014	0.003	0.103
0.017	12	8	0.5914	-0.028	0.074	0.027	-0.059
0.164	18	13.51	0.6348	-0.005	-0.110	-0.003	-0.009
0.040	24	26.77	0.2201	-0.107	-0.039	-0.021	-0.085
0.050	30	41.21	0.0513	-0.155	-0.158	-0.100	-0.070
0.107							
Tests for Normality							
Test		--Statistic--		-----p Value-----			
Shapiro-Wilk		W	0.96111	Pr < W	0.0002		
Kolmogorov-Smirnov		D	0.067041	Pr > D	0.0854		
Cramer-von Mises		W-Sq	0.223288	Pr > W-Sq	<0.0050		
Anderson-Darling		A-Sq	1.374278	Pr > A-Sq	<0.0050		

Lampiran 32 Output Program SAS untuk model ARIMAX  
Inflow Pecahan Rp10.000,00

The SAS System				06:30 Monday, May 31, 2017					
Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift		
MA1,1	-0.32949	0.08397	-3.92	0.0001	1	y	0		
AR1,1	0.42806	0.09772	4.38	<.0001	11	y	0		
AR1,2	0.57194	0.11326	5.05	<.0001	23	y	0		
NUM1	-0.32222	0.17890	-1.80	0.0739	0	t	0		
NUM2	0.30385	0.08585	3.54	0.0006	0	tD3	0		
NUM3	112.03229	11.01874	10.17	<.0001	0	M1	0		
NUM4	89.92518	10.92621	8.23	<.0001	0	M2	0		
NUM5	79.11364	10.90533	7.25	<.0001	0	M3	0		
NUM6	72.55194	10.89259	6.66	<.0001	0	M4	0		
NUM7	73.99910	10.87487	6.80	<.0001	0	M5	0		
NUM8	68.90609	10.88908	6.33	<.0001	0	M6	0		
NUM9	69.82814	11.03038	6.33	<.0001	0	M7	0		
NUM10	80.32296	11.38624	7.05	<.0001	0	M8	0		
NUM11	88.39044	11.37004	7.77	<.0001	0	M9	0		
NUM12	80.37316	11.17327	7.19	<.0001	0	M10	0		
NUM13	85.89720	11.26783	7.62	<.0001	0	M11	0		
NUM14	84.63488	11.45544	7.39	<.0001	0	M12	0		
NUM15	-23.86768	10.13076	-2.36	0.0199	0	L4	0		
NUM16	19.42829	9.75289	1.99	0.0484	0	L2t1	0		
NUM17	55.71747	12.57445	4.43	<.0001	0	L3t1	0		
NUM18	48.27275	10.35289	4.66	<.0001	0	L4t1	0		
				Variance Estimate	548.8218				
				Std Error Estimate	23.42695				
				AIC	1446.167				
				SBC	1510.214				
				Number of Residuals	156				
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
-	6	4.80	3	0.1869	-0.011	0.058	0.143	0.046	0.043
0.043	12	12.61	9	0.1812	0.001	-0.089	0.064	-0.083	0.053
0.156	18	14.98	15	0.4530	-0.072	-0.073	0.034	0.014	-0.031 -
0.029	24	26.79	21	0.1778	-0.052	-0.109	-0.169	-0.027	-0.131 -
0.060	30	30.60	27	0.2879	-0.074	-0.079	-0.025	-0.066	0.038 -
0.044									
Tests for Normality									
Test		--Statistic--			-----p Value-----				
Shapiro-Wilk		W	0.841277	Pr < W	<0.0001				
Kolmogorov-Smirnov		D	0.146585	Pr > D	<0.0100				
Cramer-von Mises		W-Sq	0.925486	Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	5.403054	Pr > A-Sq	<0.0050				

## Lampiran 33 Output Program SAS untuk model ARIMAX Inflow Pecahan Rp5.000,00

1829	The SAS System				06:30 Monday, May 31, 2017			
The ARIMA Procedure								
Conditional Least Squares Estimation								
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift	
MA1,1	-0.41327	0.09384	-4.40	<.0001	23	y	0	0
AR1,1	0.44226	0.06484	6.82	<.0001	1	y	0	0
AR1,2	0.55127	0.07407	7.44	<.0001	11	y	0	0
AR2,1	0.41168	0.09379	4.39	<.0001	12	y	0	0
NUM1	73.00401	11.85348	6.16	<.0001	0	M1	0	0
NUM2	60.31798	12.04524	5.01	<.0001	0	M2	0	0
NUM3	45.80701	12.33656	3.71	0.0003	0	M3	0	0
NUM4	37.90159	12.41188	3.05	0.0027	0	M4	0	0
NUM5	32.05505	12.41590	2.58	0.0109	0	M5	0	0
NUM6	27.77374	12.41881	2.24	0.0269	0	M6	0	0
NUM7	26.02421	12.41782	2.10	0.0379	0	M7	0	0
NUM8	35.70326	12.47651	2.86	0.0049	0	M8	0	0
NUM9	48.51589	12.49599	3.88	0.0002	0	M9	0	0
NUM10	40.65585	12.48932	3.26	0.0014	0	M10	0	0
NUM11	43.03165	12.41735	3.47	0.0007	0	M11	0	0
NUM12	55.71781	12.26063	4.54	<.0001	0	M12	0	0
NUM13	-21.76531	6.17477	-3.52	0.0006	0	L2	0	0
NUM14	-24.05431	7.75607	-3.10	0.0023	0	L3	0	0
NUM15	-20.64540	6.39584	-3.23	0.0016	0	L4	0	0
				Variance Estimate	245.8637			
				Std Error Estimate	15.68004			
				AIC	1319.194			
				SBC	1377.141			
				Number of Residuals	156			
* AIC and SBC do not include log determinant.								
Autocorrelation Check of Residuals								
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----				
6	1.89	2	0.3879	0.004	-0.073	0.003	0.004	0.031
0.073	12	13.23	8	0.1043	0.066	-0.089	0.218	-0.075
0.011	18	17.32	14	0.2397	-0.027	-0.112	0.098	-0.013
0.006	24	25.69	20	0.1764	-0.031	-0.116	-0.172	0.038
0.011	30	31.88	26	0.1970	-0.016	-0.086	-0.050	0.002
0.147								-0.008
Tests for Normality								
Test		--Statistic--		-----p Value-----				
Shapiro-Wilk		W	0.953267	Pr < W	<0.0001			
Kolmogorov-Smirnov		D	0.097095	Pr > D	<0.0100			
Cramer-von Mises		W-Sq	0.264734	Pr > W-Sq	<0.0050			
Anderson-Darling		A-Sq	1.52653	Pr > A-Sq	<0.0050			

Lampiran 34 Output Program SAS untuk model ARIMAX  
Inflow Pecahan Rp2.000,00

1997	The SAS System					06:30 Monday, May 31, 2017				
The ARIMA Procedure										
Conditional Least Squares Estimation										
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift			
AR1,1	0.43088	0.13722	3.14	0.0026	1	y	0			
NUM1	0.28015	0.10554	2.65	0.0102	0	t	0			
NUM2	24.15730	5.73345	4.21	<.0001	0	D3	0			
NUM3	1.02241	0.37468	2.73	0.0084	0	tD2	0			
NUM4	-6.89879	3.74835	-1.84	0.0707	0	M3	0			
NUM5	-13.53684	4.23853	-3.19	0.0023	0	M4	0			
NUM6	-17.61631	4.34021	-4.06	0.0001	0	M5	0			
NUM7	-20.29675	4.28789	-4.73	<.0001	0	M6	0			
NUM8	-18.08106	3.80022	-4.76	<.0001	0	M7	0			
NUM9	22.31123	3.58129	6.23	<.0001	0	M9	0			
NUM10	21.14208	3.79524	5.57	<.0001	0	M10	0			
NUM11	5.65148	3.37813	1.67	0.0996	0	M11	0			
NUM12	-25.56188	6.55623	-3.90	0.0002	0	L2	0			
NUM13	-19.32608	4.99660	-3.87	0.0003	0	L3	0			
NUM14	-21.00821	6.12909	-3.43	0.0011	0	L4	0			
NUM15	-11.92159	6.48249	-1.84	0.0709	0	L2t1	0			
NUM16	-17.38650	4.97974	-3.49	0.0009	0	L3t1	0			
NUM17	-24.99156	6.14031	-4.07	0.0001	0	L4t1	0			
				Variance Estimate	69.70301					
				Std Error Estimate	8.348833					
				AIC	560.8207					
				SBC	603.0091					
				Number of Residuals	77					
* AIC and SBC do not include log determinant.										
Autocorrelation Check of Residuals										
	To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
	6	3.56	5	0.6137	0.038	-0.009	-0.108	-0.166	-0.025	
0.037	12	12.12	11	0.3550	-0.050	-0.059	-0.070	0.124	0.258	-
0.029	18	21.79	17	0.1929	0.089	-0.281	-0.076	-0.038	-0.073	-
0.018	24	29.23	23	0.1729	-0.000	-0.116	0.063	0.099	0.141	-
0.140										
Tests for Normality										
Test				--Statistic--	-----p Value-----					
Shapiro-Wilk				W	0.983866	Pr < W	0.4386			
Kolmogorov-Smirnov				D	0.064655	Pr > D	>0.1500			
Cramer-von Mises				W-Sq	0.04386	Pr > W-Sq	>0.2500			
Anderson-Darling				A-Sq	0.313152	Pr > A-Sq	>0.2500			

## Lampiran 35 Output Program SAS untuk model ARIMAX Inflow Pecahan Rp1.000,00

The SAS System				06:30 Monday, May 31, 2017 2362			
The ARIMA Procedure							
Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.22843	0.09618	-2.38	0.0190	12	y	0
AR1,1	0.45095	0.07016	6.43	<.0001	1	y	0
AR1,2	0.48902	0.07693	6.36	<.0001	11	y	0
NUM1	-0.25031	0.09320	-2.69	0.0082	0	t	0
NUM2	-8.69827	7.48954	-1.16	0.2476	0	D2	0
NUM3	-2.10177	11.43170	-0.18	0.8544	0	D3	0
NUM4	0.22190	0.14932	1.49	0.1397	0	tD2	0
NUM5	0.10277	0.13750	0.75	0.4562	0	tD3	0
NUM6	37.87175	2.69092	14.07	<.0001	0	M1	0
NUM7	35.47377	2.73506	12.97	<.0001	0	M2	0
NUM8	32.71310	2.79607	11.70	<.0001	0	M3	0
NUM9	27.41273	2.83828	9.66	<.0001	0	M4	0
NUM10	24.53111	2.86628	8.56	<.0001	0	M5	0
NUM11	23.20303	2.88854	8.03	<.0001	0	M6	0
NUM12	22.19654	2.91507	7.61	<.0001	0	M7	0
NUM13	20.25349	2.94440	6.88	<.0001	0	M8	0
NUM14	19.43121	2.94324	6.60	<.0001	0	M9	0
NUM15	23.62193	2.93573	8.05	<.0001	0	M10	0
NUM16	27.57948	2.92116	9.44	<.0001	0	M11	0
NUM17	33.47579	2.82420	11.85	<.0001	0	M12	0
NUM18	-1.88169	2.66618	-0.71	0.4816	0	L1	0
NUM19	-4.01791	2.10014	-1.91	0.0580	0	L2	0
NUM20	-2.66494	2.11578	-1.26	0.2101	0	L3	0
NUM21	-6.00917	1.82546	-3.29	0.0013	0	L4	0
NUM22	4.94567	2.35156	2.10	0.0374	0	L1t1	0
NUM23	5.87546	1.93669	3.03	0.0029	0	L2t1	0
NUM24	-1.12914	2.20547	-0.51	0.6096	0	L3t1	0
NUM25	0.71770	2.04941	0.35	0.7268	0	L4t1	0
Variance Estimate				13.25544			
Std Error Estimate				3.640803			
AIC				871.0157			
SBC				956.4117			
Number of Residuals				156			
* AIC and SBC do not include log determinant.							
Autocorrelation Check of Residuals							
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----			
-							
6	6.45	3	0.0915	-0.065	0.092	0.072	-0.088
0.117							-0.023
12	10.70	9	0.2968	-0.081	0.055	-0.083	-0.080
0.044							-0.026
18	17.48	15	0.2911	-0.174	0.012	-0.001	-0.072
0.020							-0.057
24	30.75	21	0.0779	-0.113	-0.015	0.021	-0.112
0.174							0.124
30	38.75	27	0.0668	-0.118	0.078	-0.051	-0.114
0.036							0.071
							-
Tests for Normality							
Test	--Statistic--			-----p Value-----			
Shapiro-Wilk	W	0.971566		Pr < W	0.0026		
Kolmogorov-Smirnov	D	0.075186		Pr > D	0.0298		
Cramer-von Mises	W-Sq	0.222868		Pr > W-Sq	<0.0050		
Anderson-Darling	A-Sq	1.216072		Pr > A-Sq	<0.0050		

## Lampiran 36 Syntax Metode ARIMAX-Quantile Regression

### Model 1 pada Data *Outflow*

```

outflow=read.csv("D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAX_QR1_OUTFLOW.csv",header=TRUE)
dummysim=outflow[,1:25]
Yt=outflow[,26]
fits_Yt=outflow[,32]

##### Yt mulai kolom 26-32
##### FITS ARIMA Yt mulai kolom 33-39
##### pasangan data 26-33 27-34 28-35 29-36 30-37 31-38 32-39

xsim=cbind(dummysim, fits_Yt)
xsim=as.matrix(xsim)
xdata=as.matrix(cbind(xsim[,1],xsim[,2:5],xsim[,6:17],xsim[,18:21],xsim[,22:25],xsim[,26]))
x=xdata[1:156,1:ncol(xdata)]
Y=as.ts(Yt[1:156])
Y.testing=as.ts(Yt[157:168])

##### TSR DENGAN QUANTILE REGRESSION TAU = 0.5 #####
library(quantreg)

library(forecast)
#time series regression
tsr50=rq(Y~x-1,0.5)
summary(tsr50)
summary(tsr50,se="iid")
resitsr50=residuals(tsr50)
fittedtsr50=as.matrix(fitted(tsr50))
x=as.matrix(xdata[157:168,1:ncol(xdata)])
x.testing=data.frame(x=xdata[157:168,1:ncol(xdata)])
fore.tsr.testing50=predict(tsr50,x.testing)

##### KEBAIKAN MODEL TSR dengan QR #####
error.training=resitsr50
perc.error.training=resitsr50/Y[2:156]
mse.training=mean(error.training^2)
rmse.training=sqrt(mse.training)
mae.training=mean(abs(error.training))
mape.training=mean(abs(perc.error.training))*100
mdae.training=median(abs(error.training))
mdape.training=median(abs(perc.error.training))*100

error.testing=fore.tsr.testing50-Y.testing
perc.error.testing=error.testing/Y.testing
mse.testing=mean(error.testing^2)
rmse.testing=sqrt(mse.testing)
mae.testing=mean(abs(error.testing))
mape.testing=mean(abs(perc.error.testing))*100
mdae.testing=median(abs(error.testing))
mdape.testing=median(abs(perc.error.testing))*100

hasil.training.tsr=rbind(mse.training,rmse.training,mae.training,mape.training,mdae.training,mdape.training)
hasil.testing.tsr=rbind(mse.testing,rmse.testing,mae.testing,mape.testing,mdae.testing,mdape.testing)
hasil.model.tsr=cbind(hasil.training.tsr,hasil.testing.tsr)
colnames(hasil.model.tsr)=c("training","testing")
hasil.model.tsr

##### MENCARI BATAS ATAS DAN BAWAH #####

##### TSR DENGAN QUANTILE REGRESSION TAU = 0.025 #####

#time series regression
tsr25=rq(Y~x-1,0.025)
summary(tsr25)
summary(tsr25,se="iid")
resitsr25=residuals(tsr25)

```



```

ggtsdisplay(resitsr25,main="",lag.max=36)
fittedtsr25=as.matrix(fitted(tsr25))
x=as.matrix(xdata[157:168,1:ncol(xdata)])
x.testing=data.frame(x=xdata[157:168,1:ncol(xdata)])
fore.tsr.testing25=predict(tsr25,x.testing)

##### TSR DENGAN QUANTILE REGRESSION TAU = 0.975 #####

#time series regression
tsr975=rq(Y~x-1,0.975)
summary(tsr975)
summary(tsr975,se="iid")
resitsr975=residuals(tsr975)
ggtsdisplay(resitsr975,main="",lag.max=36)
fittedtsr975=as.matrix(fitted(tsr975))
x=as.matrix(xdata[157:168,1:ncol(xdata)])
x.testing=data.frame(x=xdata[157:168,1:ncol(xdata)])
fore.tsr.testing975=predict(tsr975,x.testing)

##### VISUALISASI #####
residual=cbind(resitsr50,resitsr25,resitsr975)
hasil.training=cbind(Y[1:156],fittedtsr25,fittedtsr50,fittedtsr975)
hasil.testing=cbind(Y[157:168],fore.tsr.testing25,fore.tsr.testing50,fore.tsr.testing975)
head(hasil.training)
tail(hasil.training)
hasil.testing

t=seq(1,155,1)
plot(t,Y[2:156],type="o",col="black",lwd=2,pch=20,cex=1,xlim=c(0,150))
lines(as.ts(fittedtsr50),type="o",col="red",lwd=2,pch=20)
lines(as.ts(fittedtsr25),type="l",col="green",lwd=2,lty=3)
lines(as.ts(fittedtsr975),type="l",col="blue",lwd=2,lty=3)
legend("topleft",c("Data Aktual","Data Ramalan","Batas Atas","Batas Bawah"),
      col=c("black","red","blue","green"),lwd=2,cex=0.8)

t1=seq(1,12,1)
plot(t1,as.ts(Y.testing),type="o",col="black",lwd=2,pch=20,cex=2,ylim=c(-10,40))
lines(as.ts(fore.tsr.testing50),type="o",col="red",lwd=2,pch=20,cex=2)
lines(as.ts(fore.tsr.testing25),type="o",col="green",lwd=2,lty=3,pch=8,cex=0.6)
lines(as.ts(fore.tsr.testing975),type="o",col="blue",lwd=2,lty=3,pch=8,cex=0.6)
legend("topleft",c("Data Aktual","Data Ramalan","Batas Atas","Batas Bawah"),
      col=c("black","red","blue","green"),lwd=2,cex=0.8)

#simpan hasil
write.table(hasil.training,"D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAXQR1_training_out100.txt")
write.table(hasil.testing,"D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAXQR1_testing_out100.txt")
write.table(residual,"D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAXQR1_residual_out100.txt")

```

## Lampiran 37 Syntax Metode ARIMAX-Quantile Regression Model 1 pada Data Inflow

```
inflow=read.csv("D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAX_QR1_INFLOW.csv",header=TRUE)
dummysim=inflow[,1:25]
Yt=inflow[,32] ##### Yt mulai kolom 26-32
fits_Yt=inflow[,39] ##### FITS ARIMA Yt mulai kolom 33-39
##### pasangan data 26-33 27-34 28-35 29-36 30-37 31-38 32-39

xsim=cbind(dummysim,fits_Yt)
xsim=as.matrix(xsim)
xdata=as.matrix(cbind(xsim[,1],xsim[,2:5],xsim[,6:17],xsim[,18:21],xsim[,22:25],xsim[,26]))
x=xdata[1:156,1:ncol(xdata)]
Y=as.ts(Yt[1:156])
Y.testing=as.ts(Yt[157:168])

##### TSR DENGAN QUANTILE REGRESSION TAU = 0.5 #####
library(quantreg)

library(forecast)
#time series regression
tsr50=rq(Y~x-1,0.5)
summary(tsr50)
summary(tsr50,se="iid")
resitsr50=residuals(tsr50)
fittedtsr50=as.matrix(fitted(tsr50))
x=as.matrix(xdata[157:168,1:ncol(xdata)])
x.testing=data.frame(x=xdata[157:168,1:ncol(xdata)])
fore.tsr.testing50=predict(tsr50,x.testing)

##### KEBAIKAN MODEL TSR dengan QR #####
error.training=resitsr50
perc.error.training=resitsr50/Y[2:156]
mse.training=mean(error.training^2)
rmse.training=sqrt(mse.training)
mae.training=mean(abs(error.training))
mape.training=mean(abs(perc.error.training))*100
mdae.training=median(abs(error.training))
mdape.training=median(abs(perc.error.training))*100

error.testing=fore.tsr.testing50-Y.testing
perc.error.testing=error.testing/Y.testing
mse.testing=mean(error.testing^2)
rmse.testing=sqrt(mse.testing)
mae.testing=mean(abs(error.testing))
mape.testing=mean(abs(perc.error.testing))*100
mdae.testing=median(abs(error.testing))
mdape.testing=median(abs(perc.error.testing))*100

hasil.training.tsr=rbind(mse.training,rmse.training,mae.training,mape.training,mdae.training,mdape.training)
hasil.testing.tsr=rbind(mse.testing,rmse.testing,mae.testing,mape.testing,mdae.testing,mdape.testing)
hasil.model.tsr=cbind(hasil.training.tsr,hasil.testing.tsr)
colnames(hasil.model.tsr)=c("training","testing")
hasil.model.tsr

##### Mencari Batas Atas dan Bawah #####

##### TSR DENGAN QUANTILE REGRESSION TAU = 0.025 #####
#time series regression
tsr25=rq(Y~x-1,0.025)
summary(tsr25)
summary(tsr25,se="iid")
resitsr25=residuals(tsr25)
ggtsdisplay(resitsr25,main="",lag.max=36)
fittedtsr25=as.matrix(fitted(tsr25))
x=as.matrix(xdata[157:168,1:ncol(xdata)])
x.testing=data.frame(x=xdata[157:168,1:ncol(xdata)])
fore.tsr.testing25=predict(tsr25,x.testing)
```

```
##### TSR DENGAN QUANTILE REGRESSION TAU = 0.975 #####

inflow=read.csv("D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAX_QR1_INFLOW.csv",header=TRUE)
dummysim=inflow[,1:25]
Yt=inflow[,32]
fits_Yt=inflow[,39]

xsim=cbind(dummysim,fits_Yt)
xsim=as.matrix(xsim)
xdata=as.matrix(cbind(xsim[,1],xsim[,2:5],xsim[,6:17],xsim[,18:21],xsim[,22:25],xsim[,26]))
x=xdata[1:156,1:ncol(xdata)]

#time series regression
tsr975=rq(Y~x-1,0.975)
summary(tsr975)
summary(tsr975,se="iid")
resitsr975=residuals(tsr975)
ggtsdisplay(resitsr975,main="",lag.max=36)
fittedtsr975=as.matrix(fitted(tsr975))
x=as.matrix(xdata[157:168,1:ncol(xdata)])
x.testing=data.frame(x=xdata[157:168,1:ncol(xdata)])
fore.tsr.testing975=predict(tsr975,x.testing)

##### VISUALISASI #####
residual=cbind(resitsr50,resitsr25,resitsr975)
hasil.training=cbind(Y[2:156],fittedtsr25,fittedtsr50,fittedtsr975)
hasil.testing=cbind(Y.testing,fore.tsr.testing25,fore.tsr.testing50,fore.tsr.testing975)
head(hasil.training)
tail(hasil.training)
hasil.testing

t=seq(1,155,1)
plot(t,Y[2:156],type="o",col="black",lwd=3,pch=20,cex=1,xlim=c(0,158),ylim=c(0,50))
lines(as.ts(fittedtsr50),type="o",col="red",lwd=3,pch=20)
lines(as.ts(fittedtsr25),type="l",col="green",lwd=3,lty=3)
lines(as.ts(fittedtsr975),type="l",col="blue",lwd=3,lty=3)
legend("topleft",c("Data Aktual","Data Ramalan","Batas Atas","Batas Bawah"),
      col=c("black","red","blue","green"),lwd=2,cex=0.8)

t=seq(1,12,1)
Y.testing=as.ts(Y.testing)
plot(t,Y.testing,type="o",col="black",lwd=3,pch=20,cex=2,ylim=c(0,25))
lines(as.ts(fore.tsr.testing50),type="o",col="red",lwd=3,pch=20,cex=2)
lines(as.ts(fore.tsr.testing25),type="o",col="green",lwd=3,lty=3,pch=8,cex=0.6)
lines(as.ts(fore.tsr.testing975),type="o",col="blue",lwd=3,lty=3,pch=8,cex=0.6)
legend("topleft",c("Data Aktual","Data Ramalan","Batas Atas","Batas Bawah"),
      col=c("black","red","blue","green"),lwd=2,cex=0.8)

#simpan hasil
write.table(hasil.training,"D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAXQR1_training_inl.txt")
write.table(hasil.testing,"D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAXQR1_testing_inl.txt")
write.table(residual,"D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU BISMILLAH/ARIMAXQR1_residual_inl.txt")
```

## Lampiran 38 Syntax Metode ARIMAX-Quantile Regression Model 3 pada Data *Outflow*

```
##### PECAHAN 100.000 #####
outflow=read.csv("D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAX_QR1_OUTFLOW.csv",header=TRUE)
dummysim=outflow[,1:25]
Yt=outflow[,26] ##### Yt mulai kolom 26-32
fits_Yt=outflow[,33] ##### FITS ARIMA Yt mulai kolom 33-39
library(quantreg) ##### pasangan data 26-33 27-34 28-35 29-36 30-37
31-38 32-39

xsim=as.matrix(dummysim)
xdata=as.matrix(cbind(xsim[,1],xsim[,2:5],xsim[,6:17],xsim[,18:21],xsim[,22:25]))
x=xdata[1:156,1:ncol(xdata)]

Y100=as.ts(Yt[1:156])
Y100.testing=as.ts(Yt[157:168])
#time series regression
tsr100=lm(Y100~x-1)
summary(tsr100)
resitsr100=residuals(tsr100)
fittedtsr100=fitted(tsr100)
x=as.matrix(xsim[157:168,1:ncol(xdata)])
x.testing=data.frame(x=xsim[157:168,1:ncol(xdata)])
fore.tsr.testing100=predict(tsr100,x.testing)

##### QUANTILE REGRESSION RESIDUAL TSR #####
library(quantmod)
error.tsr100.out=Y100.testing-fore.tsr.testing100
resitsr_100=as.vector(c(resitsr100,error.tsr100.out))
resil00.lag1=Lag(resitsr_100,k=1)
resil00.lag10=Lag(resitsr_100,k=10)
resil00.lag12=Lag(resitsr_100,k=12)
fits_Yt100.x=fits_Yt
resixy=cbind(resil00.lag1,resil00.lag10,resil00.lag12,fits_Yt100.x)
resi.xy=resixy[1:156,1:ncol(resixy)]
resitsr.y100=resitsr100[1:156]
resitsr.y100out=resitsr100[157:168]

#quantile regression
qr.resil00.50=rq(resitsr.y100~resi.xy-1,0.5)
summary(qr.resil00.50)
summary(qr.resil00.50,se="iid")
resiqr.resil00.50=residuals(qr.resil00.50)
fittedqr100.resi50=fitted(qr.resil00.50)
resi.xy=as.matrix(resixy[157:168,1:ncol(resixy)])
resil00.xyout=data.frame(resi.xy=resixy[157:168,1:ncol(resixy)])
fore.qr.testingresil00.50=predict(qr.resil00.50,resil00.xyout)

#quantile regression resitsr 0.025 dan 0.975
resixy=cbind(resil00.lag1,resil00.lag10,resil00.lag12,fits_Yt100.x)
resi.xy=resixy[1:156,1:ncol(resixy)]
qr.resil00.25=rq(resitsr.y100~resi.xy-1,0.025)
summary(qr.resil00.25)
summary(qr.resil00.25,se="iid")
resiqr.resil00.25=residuals(qr.resil00.25)
fittedqr100.resi25=fitted(qr.resil00.25)
resi.xy=as.matrix(resixy[157:168,1:ncol(resixy)])
resil00.xyout=data.frame(resi.xy=resixy[157:168,1:ncol(resixy)])
fore.qr.testingresil00.25=predict(qr.resil00.25,resil00.xyout)

resixy=cbind(resil00.lag1,resil00.lag10,resil00.lag12,fits_Yt100.x)
resi.xy=resixy[1:156,1:ncol(resixy)]
qr.resil00.975=rq(resitsr.y100~resi.xy-1,0.975)
summary(qr.resil00.975)
summary(qr.resil00.975,se="iid")
resiqr.resil00.975=residuals(qr.resil00.975)
fittedqr100.resi975=fitted(qr.resil00.975)
resi.xy=as.matrix(resixy[157:168,1:ncol(resixy)])
resil00.xyout=data.frame(resi.xy=resixy[157:168,1:ncol(resixy)])
```

```

fore.qr.testingresil100.975=predict(qr.resil100.975, resil100.xyout)

fore100.training=fittedtsr100[13:156]+fittedqr100.resi50
lower100.training=fittedtsr100[13:156]+fittedqr100.resi25
upper100.training=fittedtsr100[13:156]+fittedqr100.resi975

fore100.testing=fore.tsr.testing100+fore.qr.testingresil100.50
lower100.testing=fore.tsr.testing100+fore.qr.testingresil100.25
upper100.testing=fore.tsr.testing100+fore.qr.testingresil100.975

hasil.testing=cbind(Y100.testing, fore100.testing, lower100.testing, upper100.testing)
hasil.testing

t=seq(1,144,1)
Y=Y100[13:156]
plot(t,Y,type="o", col="black", lwd=3, pch=20, cex=1)
lines(as.ts(fore100.training), type="o", col="red", lwd=3, pch=20, cex=1)
lines(as.ts(lower100.training), type="o", col="green", lwd=3, lty=3, pch=8, cex=0.4)
lines(as.ts(upper100.training), type="o", col="blue", lwd=3, lty=3, pch=8, cex=0.4)
legend("topleft", c("Data Aktual", "Data Ramalan tau=0.5", "Data Ramalan tau=0.025", "Data Ramalan
tau=0.975"),
      col=c("black", "red", "blue", "green"), lwd=0.5, cex=1)

Bulan=seq(1,12,1)
plot(Bulan,Y100.testing,type="o", col="black", lwd=4, pch=20, cex=2, ylim=c(-500,10000))
lines(as.ts(fore100.testing), type="o", col="red", lwd=4, pch=20, cex=2)
lines(as.ts(lower100.testing), type="o", col="green", lwd=4, lty=3, pch=8, cex=0.6)
lines(as.ts(upper100.testing), type="o", col="blue", lwd=4, lty=3, pch=8, cex=0.6)
legend("topleft", c("Data Aktual", "Data Ramalan tau=0.5", "Data Ramalan tau=0.025", "Data Ramalan
tau=0.975"),
      col=c("black", "red", "blue", "green"), lwd=0.5, cex=1)

testing100=cbind(Y100.testing, fore.tsr.testing100, error.tsr100.out,
fore.qr.testingresil100.25, fore.qr.testingresil100.50, fore.qr.testingresil100.975,
lower100.testing, fore100.testing, upper100.testing)
testing100

##### KEBAIKAN MODEL TSR dengan QR #####
error.training=resiqr.resil100.50
perc.error.training=error.training/Y
mse.training=mean(error.training^2)
rmse.training=sqrt(mse.training)
mae.training=mean(abs(error.training))
mape.training=mean(abs(perc.error.training))*100
mdae.training=median(abs(error.training))
mdape.training=median(abs(perc.error.training))*100

error.testing=fore100.testing-Y100.testing
perc.error.testing=error.testing/Y100.testing
mse.testing=mean(error.testing^2)
rmse.testing=sqrt(mse.testing)
mae.testing=mean(abs(error.testing))
mape.testing=mean(abs(perc.error.testing))*100
mdae.testing=median(abs(error.testing))
mdape.testing=median(abs(perc.error.testing))*100

hasil.training.tsr=rbind(mse.training, rmse.training, mae.training, mape.training, mdae.training, mdape.
e.training)
hasil.testing.tsr=rbind(mse.testing, rmse.testing, mae.testing, mape.testing, mdae.testing, mdape.test
ing)
akurasi100=cbind(hasil.training.tsr, hasil.testing.tsr)
colnames(akurasi100)=c("training", "testing")
akurasi100

```

## Lampiran 39 Syntax Metode ARIMAX-Quantile Regression Model 3 pada Data *Inflow*

```
##### PECAHAN 100.000 #####
inflow=read.csv("D:/ITS/AJENG TUGAS AKHIR/BAB 4/BARU
BISMILLAH/ARIMAX_QR1 INFLOW.csv",header=TRUE)
dummysim=inflow[,1:25]
Yt=inflow[,26]          ##### Yt mulai kolom 26-32
fits_Yt=inflow[,33]      ##### FITS ARIMA Yt mulai kolom 33-39
library(quantreg)        ##### pasangan data 26-33 27-34 28-35 29-36 30-37
31-38 32-39

xsim=as.matrix(dummysim)
xdata=as.matrix(cbind(xsim[,1],xsim[,2:5],xsim[,6:17],xsim[,18:21],xsim[,22:25]))
x=xdata[1:156,1:ncol(xdata)]

Y100=as.ts(Yt[1:156])
Y100.testing=as.ts(Yt[157:168])
#time series regression
tsr100=lm(Y100~x-1)
summary(tsr100)
resitsr100=residuals(tsr100)
fittedtsr100=fitted(tsr100)
x=as.matrix(xsim[157:168,1:ncol(xdata)])
x.testing=data.frame(x=xsim[157:168,1:ncol(xdata)])
fore.tsr.testing100=predict(tsr100,x.testing)

##### QUANTILE REGRESSION RESIDUAL TSR #####
library(quantmod)
error.tsr100.out=Y100.testing-fore.tsr.testing100
resitsr_100=as.vector(c(resitsr100,error.tsr100.out))
fits_Yt100.x=fits_Yt
resixy=cbind(fits_Yt100.x)
resi.xy=resixy[1:156,1:ncol(resixy)]
resitsr.y100=resitsr100[1:156]
resitsr.y100out=resitsr100[157:168]

#quantile regression
qr.resi100.50=rq(resitsr.y100~resi.xy-1,0.5)
summary(qr.resi100.50)
summary(qr.resi100.50,se="iid")
resiqr.resi100.50=residuals(qr.resi100.50)
fittedqr100.resi50=fitted(qr.resi100.50)
resi.xy=as.matrix(resixy[157:168,1:ncol(resixy)])
resi100.xyout=data.frame(resi.xy=resixy[157:168,1:ncol(resixy)])
fore.qr.testingresi100.50=predict(qr.resi100.50,resi100.xyout)

#quantile regression resitsr 0.025 dan 0.975
resixy=cbind(fits_Yt100.x)
resi.xy=resixy[1:156,1:ncol(resixy)]
qr.resi100.25=rq(resitsr.y100~resi.xy-1,0.025)
summary(qr.resi100.25)
summary(qr.resi100.25,se="iid")
resiqr.resi100.25=residuals(qr.resi100.25)
fittedqr100.resi25=fitted(qr.resi100.25)
resi.xy=as.matrix(resixy[157:168,1:ncol(resixy)])
resi100.xyout=data.frame(resi.xy=resixy[157:168,1:ncol(resixy)])
fore.qr.testingresi100.25=predict(qr.resi100.25,resi100.xyout)

resixy=cbind(fits_Yt100.x)
resi.xy=resixy[1:156,1:ncol(resixy)]
qr.resi100.975=rq(resitsr.y100~resi.xy-1,0.975)
summary(qr.resi100.975)
summary(qr.resi100.975,se="iid")
resiqr.resi100.975=residuals(qr.resi100.975)
fittedqr100.resi975=fitted(qr.resi100.975)
resi.xy=as.matrix(resixy[157:168,1:ncol(resixy)])
resi100.xyout=data.frame(resi.xy=resixy[157:168,1:ncol(resixy)])
fore.qr.testingresi100.975=predict(qr.resi100.975,resi100.xyout)

fore100.training=fittedtsr100[2:156]+fittedqr100.resi50
```

```

lower100.training=fittedtsr100[2:156]+fittedqr100.resi25
upper100.training=fittedtsr100[2:156]+fittedqr100.resi975

fore100.testing=fore.tsr.testing100+fore.qr.testingresil100.50
lower100.testing=fore.tsr.testing100+fore.qr.testingresil100.25
upper100.testing=fore.tsr.testing100+fore.qr.testingresil100.975

hasil.testing100=cbind(Y100.testing,fore100.testing,lower100.testing,upper100.testing)
hasil.testing100

t=seq(1,155,1)
Y=Y100[2:156]
plot(t,Y,type="o",col="black",lwd=3,pch=20,cex=1)
lines(as.ts(fore100.training),type="o",col="red",lwd=3,pch=20,cex=1)
lines(as.ts(lower100.training),type="o",col="green",lwd=3,lty=3,pch=8,cex=0.4)
lines(as.ts(upper100.training),type="o",col="blue",lwd=3,lty=3,pch=8,cex=0.4)
legend("topleft",c("Data Aktual","Data Ramalan tau=0.5","Data Ramalan tau=0.025","Data Ramalan
tau=0.975"),
      col=c("black","red","blue","green"),lwd=0.5,cex=0.8)

Bulan=seq(1,12,1)
plot(Bulan,Y100.testing,type="o",col="black",lwd=4,pch=20,cex=2,ylim=c(-500,10000))
lines(as.ts(fore100.testing),type="o",col="red",lwd=4,pch=20,cex=2)
lines(as.ts(lower100.testing),type="o",col="green",lwd=4,lty=3,pch=8,cex=0.6)
lines(as.ts(upper100.testing),type="o",col="blue",lwd=4,lty=3,pch=8,cex=0.6)
legend("topleft",c("Data Aktual","Data Ramalan tau=0.5","Data Ramalan tau=0.025","Data Ramalan
tau=0.975"),
      col=c("black","red","blue","green"),lwd=0.5,cex=1)

testing100=cbind(Y100.testing,fore.tsr.testing100,error.tsr100.out,
fore.qr.testingresil100.25,fore.qr.testingresil100.50,fore.qr.testingresil100.975,
lower100.testing,fore100.testing,upper100.testing)
testing100

##### KEBAIKAN MODEL TSR dengan QR #####
error.training=resigr.resil100.50
perc.error.training=error.training/Y
mse.training=mean(error.training^2)
rmse.training=sqrt(mse.training)
mae.training=mean(abs(error.training))
mape.training=mean(abs(perc.error.training))*100
mdae.training=median(abs(error.training))
mdape.training=median(abs(perc.error.training))*100

error.testing=fore100.testing-Y100.testing
perc.error.testing=error.testing/Y100.testing
mse.testing=mean(error.testing^2)
rmse.testing=sqrt(mse.testing)
mae.testing=mean(abs(error.testing))
mape.testing=mean(abs(perc.error.testing))*100
mdae.testing=median(abs(error.testing))
mdape.testing=median(abs(perc.error.testing))*100

hasil.training.tsr=rbind(mse.training,rmse.training,mae.training,mape.training,mdae.training,mdape.
e.training)
hasil.testing.tsr=rbind(mse.testing,rmse.testing,mae.testing,mape.testing,mdae.testing,mdape.test
ing)
akurasi100=cbind(hasil.training.tsr,hasil.testing.tsr)
colnames(akurasi100)=c("training","testing")
akurasi100

```

**Lampiran 40** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Outflow* Rp100.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	5,268	0,000	5,052	0,210	11,154	0,000
D2.t	-283,659	0,005	-347,073	0,252	-750,721	0,000
D3.t	-331,595	0,012	-1189,729	0,004	-4095,152	0,000
Td2.t	-4,010	0,027	-2,373	0,667	-0,953	0,751
Td3.t	-0,435	0,784	8,513	0,083	30,703	0,000
M1.t	-40,190	0,418	201,457	0,187	254,538	0,003
M2.t	125,755	0,009	161,757	0,267	552,864	0,000
M3.t	489,746	0,000	503,791	0,001	701,269	0,000
M4.t	332,145	0,000	646,682	0,000	971,833	0,000
M5.t	418,609	0,000	623,115	0,000	760,406	0,000
M6.t	577,927	0,000	803,783	0,000	1519,184	0,000
M7.t	489,960	0,000	666,288	0,000	912,796	0,000
M8.t	-143,934	0,006	542,783	0,001	1439,130	0,000
M9.t	-220,847	0,000	500,021	0,002	547,406	0,000
M10.t	543,189	0,000	320,195	0,051	643,528	0,000
M11.t	402,503	0,000	344,933	0,029	591,621	0,000
M12.t	486,334	0,000	1328,096	0,000	1497,118	0,000
C1.t	-386,051	0,000	-287,953	0,287	-696,451	0,000
C2.t	21,109	0,745	340,997	0,089	40,621	0,709
C3.t	1845,858	0,000	1031,397	0,000	861,960	0,000
C4.t	682,263	0,000	607,901	0,003	4056,018	0,000
C1.t.1	1842,883	0,000	1897,319	0,000	1794,717	0,000
C2.t.1	501,802	0,000	886,689	0,000	1886,571	0,000
C3.t.1	719,713	0,000	128,854	0,559	-363,091	0,003
C4.t.1	158,446	0,012	288,130	0,134	363,784	0,001
FITS	0,324	0,000	0,428	0,000	0,389	0,000



**Lampiran 41** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Outflow* Rp50.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	8,210	0,000	2,617	0,560	7,214	0,001
D2.t	-455,796	0,000	-666,244	0,044	-157,231	0,297
D3.t	-677,316	0,000	-1175,016	0,005	-1306,975	0,000
Td2.t	-6,165	0,005	1,527	0,798	-8,119	0,004
Td3.t	-0,981	0,595	8,473	0,100	8,296	0,001
M1.t	122,747	0,052	342,381	0,051	441,691	0,000
M2.t	457,957	0,000	474,490	0,006	606,976	0,000
M3.t	565,957	0,000	762,596	0,000	1009,738	0,000
M4.t	690,095	0,000	800,895	0,000	983,853	0,000
M5.t	517,055	0,000	753,042	0,000	972,637	0,000
M6.t	744,394	0,000	1003,228	0,000	1060,376	0,000
M7.t	613,172	0,000	916,271	0,000	1011,638	0,000
M8.t	-92,193	0,188	664,156	0,001	1396,322	0,000
M9.t	101,734	0,124	523,045	0,005	1034,098	0,000
M10.t	694,077	0,000	728,557	0,000	643,351	0,000
M11.t	579,256	0,000	603,584	0,001	1040,090	0,000
M12.t	403,300	0,000	1267,277	0,000	1773,713	0,000
C1.t	-472,900	0,000	-907,531	0,005	-882,907	0,000
C2.t	1301,094	0,000	915,774	0,000	1418,479	0,000
C3.t	2466,200	0,000	1725,270	0,000	1798,001	0,000
C4.t	858,224	0,000	1299,334	0,000	2246,002	0,000
C1.t.1	1716,600	0,000	1457,420	0,000	2260,468	0,000
C2.t.1	527,402	0,000	631,566	0,003	1225,201	0,000
C3.t.1	781,995	0,000	94,920	0,688	-326,832	0,003
C4.t.1	43,866	0,553	70,315	0,732	175,860	0,064
FITS	0,094	0,010	0,350	0,001	0,321	0,000

**Lampiran 42** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Outflow* Rp20.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	-0,464	0,000	-0,825	0,000	0,551	0,000
D2.t	-50,275	0,000	-78,236	0,000	-76,912	0,000
D3.t	-50,077	0,000	-95,681	0,000	-136,052	0,000
Td2.t	0,178	0,055	0,723	0,004	-0,382	0,010
Td3.t	0,326	0,000	0,949	0,000	0,140	0,273
M1.t	84,773	0,000	107,612	0,000	106,235	0,000
M2.t	94,966	0,000	113,042	0,000	105,721	0,000
M3.t	90,078	0,000	121,409	0,000	117,059	0,000
M4.t	99,622	0,000	124,204	0,000	123,719	0,000
M5.t	83,577	0,000	130,049	0,000	138,921	0,000
M6.t	72,413	0,000	161,714	0,000	165,653	0,000
M7.t	134,402	0,000	152,879	0,000	171,768	0,000
M8.t	70,437	0,000	169,147	0,000	184,619	0,000
M9.t	70,236	0,000	84,839	0,000	130,758	0,000
M10.t	75,671	0,000	93,193	0,000	83,083	0,000
M11.t	82,781	0,000	100,864	0,000	93,872	0,000
M12.t	82,442	0,000	121,967	0,000	128,635	0,000
C1.t	1,120	0,810	-20,098	0,112	-12,074	0,104
C2.t	28,833	0,000	84,539	0,000	120,975	0,000
C3.t	153,847	0,000	112,759	0,000	152,080	0,000
C4.t	129,195	0,000	226,569	0,000	221,006	0,000
C1.t.1	179,301	0,000	194,540	0,000	130,848	0,000
C2.t.1	122,031	0,000	141,332	0,000	260,143	0,000
C3.t.1	155,994	0,000	281,273	0,000	446,875	0,000
C4.t.1	78,749	0,000	74,053	0,000	106,839	0,000
FITS	0,024	0,000	0,092	0,000	0,069	0,000

### Lampiran 43 Hasil Uji Signifikansi Parameter ARIMAX-QR

Model 1 pada Data *Outflow* Rp10.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	-0,630	0,000	-0,101	0,368	-0,520	0,000
D2,t	-3,776	0,322	1,810	0,837	-33,871	0,000
D3,t	-40,873	0,000	-26,630	0,013	-72,363	0,000
Td2,t	0,333	0,000	-0,124	0,431	0,531	0,000
Td3,t	0,704	0,000	0,240	0,082	0,890	0,000
M1,t	39,389	0,000	28,055	0,000	59,319	0,000
M2,t	41,553	0,000	32,574	0,000	56,817	0,000
M3,t	44,983	0,000	35,480	0,000	83,673	0,000
M4,t	55,871	0,000	48,569	0,000	69,106	0,000
M5,t	53,915	0,000	40,547	0,000	93,635	0,000
M6,t	47,109	0,000	57,822	0,000	75,344	0,000
M7,t	58,042	0,000	57,250	0,000	119,934	0,000
M8,t	26,172	0,000	50,997	0,000	81,550	0,000
M9,t	34,085	0,000	9,804	0,032	54,991	0,000
M10,t	36,080	0,000	15,823	0,001	39,838	0,000
M11,t	32,730	0,000	20,514	0,000	54,590	0,000
M12,t	37,732	0,000	35,819	0,000	65,663	0,000
C1,t	-3,106	0,367	-4,056	0,610	-11,865	0,058
C2,t	34,471	0,000	17,770	0,003	45,408	0,000
C3,t	70,171	0,000	114,720	0,000	174,117	0,000
C4,t	122,054	0,000	115,296	0,000	288,151	0,000
C1,t,1	85,832	0,000	64,693	0,000	56,106	0,000
C2,t,1	83,909	0,000	143,502	0,000	426,866	0,000
C3,t,1	70,166	0,000	182,229	0,000	465,839	0,000
C4,t,1	55,363	0,000	59,868	0,000	123,048	0,000
FITS	0,069	0,000	0,339	0,000	0,414	0,000

**Lampiran 44** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Outflow* Rp5.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	-0.143	0.000	0.061	0.670	0.142	0.004
D2.t	3.120	0.169	6.978	0.533	69.096	0.000
D3.t	-20.368	0.000	-17.541	0.196	-93.815	0.000
Td2.t	-0.082	0.044	-0.293	0.145	-1.211	0.000
Td3.t	0.180	0.000	-0.008	0.962	0.586	0.000
M1.t	21.034	0.000	21.790	0.000	37.159	0.000
M2.t	21.876	0.000	28.167	0.000	42.216	0.000
M3.t	24.943	0.000	30.981	0.000	38.493	0.000
M4.t	30.708	0.000	36.796	0.000	53.893	0.000
M5.t	30.739	0.000	40.365	0.000	64.008	0.000
M6.t	37.788	0.000	49.954	0.000	86.686	0.000
M7.t	40.063	0.000	49.633	0.000	82.278	0.000
M8.t	17.632	0.000	42.008	0.000	70.948	0.000
M9.t	18.394	0.000	14.436	0.012	45.250	0.000
M10.t	17.475	0.000	14.884	0.010	39.529	0.000
M11.t	21.215	0.000	17.999	0.002	40.424	0.000
M12.t	21.904	0.000	31.806	0.000	36.875	0.000
C1.t	6.023	0.004	35.335	0.001	7.579	0.030
C2.t	33.086	0.000	34.385	0.000	34.780	0.000
C3.t	149.447	0.000	243.714	0.000	271.884	0.000
C4.t	93.181	0.000	94.182	0.000	380.648	0.000
C1.t.l	126.610	0.000	122.303	0.000	165.477	0.000
C2.t.l	78.039	0.000	103.767	0.000	389.539	0.000
C3.t.l	41.413	0.000	188.096	0.000	471.652	0.000
C4.t.l	49.421	0.000	49.990	0.000	78.961	0.000
FITS	0.003	0.000	0.002	0.441	-0.001	0.243

**Lampiran 45** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Outflow* Rp2.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	0,026	0,000	0,040	0,021	0,052	0,000
D2.t	12,508	0,000	12,290	0,000	16,515	0,000
D3.t	0,432	0,248	0,402	0,739	5,238	0,000
Td2.t	-0,817	0,000	-0,681	0,000	-0,311	0,000
M1.t	-1,496	0,000	-1,058	0,391	-4,957	0,000
M2.t	-2,131	0,000	-0,188	0,878	-3,029	0,000
M3.t	-1,203	0,002	0,607	0,620	-4,053	0,000
M4.t	-0,058	0,878	1,596	0,194	-3,141	0,000
M5.t	0,107	0,775	1,368	0,265	7,983	0,000
M6.t	2,526	0,000	2,380	0,084	1,196	0,019
M7.t	-27,086	0,000	-24,126	0,000	17,881	0,000
M8.t	-6,493	0,000	-7,133	0,000	-8,270	0,000
M9.t	-7,391	0,000	-1,969	0,117	-6,318	0,000
M10.t	-2,409	0,000	-2,212	0,062	-6,640	0,000
M11.t	-2,139	0,000	-2,403	0,043	-6,379	0,000
C2.t	-10,402	0,000	-1,145	0,573	-5,200	0,000
C3.t	65,777	0,000	88,072	0,000	87,432	0,000
C4.t	149,666	0,000	149,276	0,000	174,438	0,000
C2.t.1	268,328	0,000	267,511	0,000	259,965	0,000
C3.t.1	37,244	0,000	39,937	0,000	152,451	0,000
C4.t.1	17,066	0,000	17,515	0,000	15,234	0,000
FITS	0,544	0,000	0,530	0,000	0,502	0,000

**Lampiran 46** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Outflow* Rp1.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	0,015	0,066	-0,193	0,000	-0,253	0,000
D2.t	7,862	0,000	4,220	0,000	5,074	0,000
D3.t	-6,630	0,000	-15,725	0,000	-16,739	0,000
Td2.t	-0,205	0,000	-0,024	0,093	0,017	0,082
Td3.t	-0,038	0,000	0,189	0,000	0,248	0,000
M1.t	9,156	0,000	16,899	0,000	18,703	0,000
M2.t	5,597	0,000	16,795	0,000	18,837	0,000
M3.t	9,933	0,000	16,906	0,000	18,395	0,000
M4.t	9,004	0,000	16,852	0,000	20,077	0,000
M5.t	7,597	0,000	16,814	0,000	18,566	0,000
M6.t	8,529	0,000	16,783	0,000	21,222	0,000
M7.t	5,242	0,000	17,897	0,000	22,556	0,000
M8.t	10,316	0,000	18,891	0,000	23,661	0,000
M9.t	9,648	0,000	20,044	0,000	26,465	0,000
M10.t	9,506	0,000	16,647	0,000	22,194	0,000
M11.t	9,518	0,000	16,712	0,000	17,789	0,000
M12.t	6,794	0,000	16,809	0,000	18,500	0,000
C1.t	-2,142	0,001	-2,699	0,000	-11,990	0,000
C2.t	3,050	0,000	0,030	0,956	30,049	0,000
C3.t	5,776	0,000	11,402	0,000	8,342	0,000
C4.t	23,225	0,000	29,752	0,000	84,685	0,000
C1.t.l	35,852	0,000	32,726	0,000	26,027	0,000
C2.t.l	17,615	0,000	18,340	0,000	20,326	0,000
C3.t.l	2,026	0,000	0,026	0,964	-2,721	0,000
C4.t.l	5,264	0,000	3,441	0,000	25,054	0,000
FITS	-0,024	0,002	0,087	0,000	0,202	0,000

**Lampiran 47** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Inflow* Rp100.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	4,039	0,000	8,673	0,025	8,747	0,000
D2.t	-650,632	0,000	-964,953	0,001	-449,442	0,000
D3.t	-2080,671	0,000	-1752,420	0,000	-1182,730	0,000
Td2.t	-0,009	0,995	1,263	0,811	-4,228	0,041
Td3.t	19,543	0,000	12,164	0,018	8,148	0,000
M1.t	1155,812	0,000	1796,099	0,000	3105,167	0,000
M2.t	916,766	0,000	824,604	0,000	1134,262	0,000
M3.t	740,137	0,000	624,422	0,000	617,002	0,000
M4.t	858,220	0,000	618,100	0,000	724,780	0,000
M5.t	920,559	0,000	753,185	0,000	698,658	0,000
M6.t	670,525	0,000	684,659	0,000	619,933	0,000
M7.t	647,840	0,000	721,069	0,000	895,052	0,000
M8.t	730,149	0,000	779,066	0,000	1061,267	0,000
M9.t	613,323	0,000	799,006	0,000	815,969	0,000
M10.t	635,682	0,000	841,065	0,000	880,450	0,000
M11.t	603,638	0,000	689,197	0,000	684,667	0,000
M12.t	195,305	0,000	366,216	0,024	489,171	0,000
C1.t	2012,603	0,000	1411,587	0,000	1499,770	0,000
C2.t	911,715	0,000	1448,788	0,000	3475,563	0,000
C3.t	229,535	0,000	1076,112	0,000	3576,198	0,000
C4.t	-962,248	0,000	-452,976	0,015	-111,474	0,120
C1.t.1	380,088	0,000	248,071	0,344	335,231	0,001
C2.t.1	533,090	0,000	248,151	0,181	-40,340	0,575
C3.t.1	1196,988	0,000	679,339	0,002	1397,736	0,000
C4.t.1	1589,646	0,000	1569,935	0,000	4972,633	0,000
FITS	0,005	0,812	0,190	0,006	0,337	0,000

**Lampiran 48** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Inflow* Rp50.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	12,308	0,000	9,524	0,001	21,871	0,000
D2.t	-250,165	0,017	-556,138	0,008	-780,127	0,000
D3.t	-1055,630	0,000	-985,689	0,000	-704,930	0,000
Td2.t	-13,915	0,000	-5,792	0,119	-12,665	0,000
Td3.t	-1,661	0,298	1,165	0,713	-11,409	0,000
M1.t	1033,961	0,000	1643,711	0,000	2247,109	0,000
M2.t	660,651	0,000	901,718	0,000	1309,883	0,000
M3.t	625,881	0,000	726,529	0,000	953,486	0,000
M4.t	769,852	0,000	730,106	0,000	1141,199	0,000
M5.t	794,090	0,000	814,384	0,000	1088,918	0,000
M6.t	640,516	0,000	795,947	0,000	899,124	0,000
M7.t	815,584	0,000	836,761	0,000	1038,648	0,000
M8.t	711,582	0,000	924,656	0,000	1249,013	0,000
M9.t	695,087	0,000	818,672	0,000	1090,553	0,000
M10.t	788,144	0,000	931,513	0,000	1051,468	0,000
M11.t	816,633	0,000	708,761	0,000	1214,393	0,000
M12.t	-267,703	0,000	575,348	0,000	868,055	0,000
C1.t	1734,879	0,000	1728,967	0,000	1815,799	0,000
C2.t	1295,457	0,000	1416,288	0,000	2126,817	0,000
C3.t	129,313	0,084	638,887	0,000	1343,952	0,000
C4.t	-655,322	0,000	-447,181	0,001	-101,692	0,072
C1.t.1	159,089	0,081	205,797	0,254	-162,251	0,041
C2.t.1	325,329	0,000	352,954	0,011	336,021	0,000
C3.t.1	594,450	0,000	326,715	0,067	1904,567	0,000
C4.t.1	600,488	0,000	1565,557	0,000	2698,809	0,000
FITS	0,170	0,000	0,264	0,000	0,078	0,007



**Lampiran 49** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Inflow* Rp20.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	-0,307	0,001	-0,647	0,008	-1,007	0,000
D2.t	-7,320	0,291	-32,500	0,088	-86,637	0,000
D3.t	-5,038	0,541	-85,199	0,000	-89,042	0,000
Td2.t	-0,193	0,111	0,179	0,588	1,721	0,000
Td3.t	-0,066	0,531	0,791	0,007	1,436	0,000
M1.t	108,093	0,000	140,956	0,000	77,708	0,000
M2.t	75,623	0,000	116,015	0,000	78,101	0,000
M3.t	70,431	0,000	107,138	0,000	53,262	0,000
M4.t	71,276	0,000	99,897	0,000	62,064	0,000
M5.t	74,353	0,000	101,253	0,000	65,916	0,000
M6.t	67,771	0,000	94,340	0,000	65,990	0,000
M7.t	59,528	0,000	98,996	0,000	58,130	0,000
M8.t	71,162	0,000	104,611	0,000	77,021	0,000
M9.t	68,422	0,000	107,096	0,000	71,534	0,000
M10.t	96,291	0,000	106,202	0,000	67,074	0,000
M11.t	58,936	0,000	115,370	0,000	126,362	0,000
M12.t	45,590	0,000	105,710	0,000	70,206	0,000
C1.t	13,881	0,021	24,216	0,140	4,247	0,719
C2.t	0,635	0,883	39,005	0,001	52,385	0,000
C3.t	8,456	0,088	-1,745	0,897	11,842	0,226
C4.t	-27,493	0,000	-26,773	0,024	-36,148	0,000
C1.t.1	77,090	0,000	27,347	0,096	-41,264	0,001
C2.t.1	61,658	0,000	23,235	0,066	-16,373	0,072
C3.t.1	32,844	0,000	114,152	0,000	57,480	0,000
C4.t.1	129,229	0,000	122,432	0,000	153,987	0,000
FITS	0,370	0,000	0,413	0,000	0,900	0,000

**Lampiran 50** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Inflow* Rp10.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	-0,514	0,000	-0,498	0,000	-0,776	0,000
D2.t	11,362	0,055	5,613	0,595	-12,084	0,037
D3.t	-9,929	0,166	-12,029	0,349	-48,964	0,000
Td2.t	-0,110	0,298	0,050	0,794	0,555	0,000
Td3.t	0,441	0,000	0,472	0,005	1,036	0,000
M1.t	93,796	0,000	89,044	0,000	156,772	0,000
M2.t	81,595	0,000	68,118	0,000	76,171	0,000
M3.t	59,904	0,000	57,898	0,000	66,215	0,000
M4.t	63,346	0,000	53,645	0,000	58,429	0,000
M5.t	55,734	0,000	55,354	0,000	58,704	0,000
M6.t	47,191	0,000	45,676	0,000	54,276	0,000
M7.t	37,867	0,000	45,460	0,000	55,216	0,000
M8.t	54,918	0,000	52,758	0,000	75,042	0,000
M9.t	54,940	0,000	52,467	0,000	179,434	0,000
M10.t	59,062	0,000	61,724	0,000	114,172	0,000
M11.t	67,796	0,000	69,467	0,000	164,232	0,000
M12.t	82,120	0,000	63,661	0,000	84,073	0,000
C1.t	35,079	0,000	19,477	0,042	-35,992	0,000
C2.t	15,547	0,000	15,844	0,020	-9,700	0,009
C3.t	-8,900	0,041	-2,455	0,751	-19,063	0,000
C4.t	-23,883	0,000	-24,804	0,000	-43,036	0,000
C1.t.1	20,883	0,000	14,845	0,119	-8,325	0,108
C2.t.1	41,628	0,000	61,054	0,000	36,759	0,000
C3.t.1	46,396	0,000	107,771	0,000	198,348	0,000
C4.t.1	44,537	0,000	43,433	0,000	90,584	0,000
FITS	0,046	0,000	0,300	0,000	0,435	0,000

**Lampiran 51** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Inflow* Rp5.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	-0,547	0,000	-0,264	0,000	-0,648	0,000
D2.t	-37,640	0,001	-10,279	0,030	-40,790	0,000
D3.t	-38,300	0,007	-0,375	0,948	-60,194	0,000
Td2.t	0,844	0,000	0,209	0,015	1,036	0,000
Td3.t	0,753	0,000	0,205	0,006	1,021	0,000
M1.t	33,255	0,000	27,593	0,000	88,149	0,000
M2.t	22,795	0,000	16,398	0,000	40,619	0,000
M3.t	23,082	0,000	13,100	0,000	27,123	0,000
M4.t	20,818	0,000	12,242	0,000	53,754	0,000
M5.t	22,227	0,000	9,572	0,000	24,911	0,000
M6.t	21,099	0,000	12,427	0,000	23,964	0,000
M7.t	17,007	0,003	11,569	0,000	24,094	0,000
M8.t	19,993	0,001	16,963	0,000	30,418	0,000
M9.t	27,919	0,000	12,351	0,000	76,296	0,000
M10.t	23,665	0,000	16,530	0,000	37,988	0,000
M11.t	16,303	0,013	6,923	0,010	33,612	0,000
M12.t	16,797	0,010	10,883	0,000	22,245	0,000
C1.t	3,680	0,724	14,827	0,001	-1,579	0,763
C2.t	-11,719	0,113	-1,322	0,660	-36,271	0,000
C3.t	-16,968	0,046	-29,772	0,000	-42,024	0,000
C4.t	-10,387	0,167	-12,125	0,000	-23,797	0,000
C1.t.1	34,977	0,001	45,096	0,000	13,988	0,008
C2.t.1	27,348	0,000	34,701	0,000	-8,325	0,026
C3.t.1	11,440	0,189	28,413	0,000	-18,803	0,000
C4.t.1	29,251	0,000	37,319	0,000	4,731	0,202
FITS	0,797	0,000	0,598	0,000	1,061	0,000

**Lampiran 52** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Inflow* Rp2.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	0,054	0,000	0,174	0,064	0,207	0,000
D2	-11,779	0,000	-5,889	0,439	-12,711	0,000
D3	18,427	0,000	7,109	0,365	23,609	0,000
Td2	1,764	0,000	1,023	0,105	2,728	0,000
M1.t	1,265	0,155	-0,982	0,877	-0,545	0,770
M2.t	-3,633	0,000	-1,867	0,772	-3,558	0,063
M3.t	-4,725	0,000	1,176	0,859	-9,979	0,000
M4.t	-7,513	0,000	-3,793	0,576	-12,450	0,000
M5.t	-9,529	0,000	-8,578	0,230	-15,521	0,000
M6.t	-13,095	0,000	-8,527	0,247	-17,858	0,000
M7.t	-15,876	0,000	-8,428	0,267	-22,122	0,000
M8.t	-10,668	0,000	5,107	0,483	10,192	0,000
M9.t	16,408	0,000	18,374	0,011	19,245	0,000
M10.t	23,152	0,000	13,028	0,044	27,823	0,000
M11.t	2,253	0,009	1,226	0,840	4,025	0,027
C2.t	-27,200	0,000	-26,960	0,007	-39,689	0,000
C3.t	-6,911	0,000	-13,652	0,088	-4,672	0,046
C4.t	-6,355	0,000	-9,184	0,318	-11,808	0,000
C2.t.1	-22,674	0,000	-1,442	0,878	-14,707	0,000
C3.t.1	-16,705	0,000	-11,049	0,160	-20,238	0,000
C4.t.1	-11,259	0,000	-2,372	0,815	-24,110	0,000
FITS	0,223	0,000	0,578	0,000	0,413	0,000

**Lampiran 53** Hasil Uji Signifikansi Parameter ARIMAX-QR  
Model 1 pada Data *Inflow* Rp1.000,00

Variabel	= 0,025		= 0,50		= 0,975	
	Koefisien	P-value	Koefisien	P-value	Koefisien	P-value
t	0,056	0,000	-0,081	0,004	-0,123	0,000
D2	3,714	0,000	-5,234	0,011	-5,522	0,000
D3	1,749	0,052	-3,248	0,182	-4,268	0,002
Td2	-0,103	0,000	0,103	0,006	0,150	0,000
Td3	-0,076	0,000	0,060	0,061	0,113	0,000
M1.t	1,294	0,031	9,106	0,000	26,714	0,000
M2.t	2,439	0,000	7,625	0,000	14,721	0,000
M3.t	1,417	0,012	7,861	0,000	13,369	0,000
M4.t	1,145	0,030	6,900	0,000	9,204	0,000
M5.t	1,332	0,008	6,303	0,000	9,096	0,000
M6.t	1,141	0,020	6,643	0,000	7,323	0,000
M7.t	0,930	0,053	5,672	0,000	7,869	0,000
M8.t	-0,361	0,446	5,167	0,000	7,772	0,000
M9.t	-0,065	0,891	4,644	0,000	7,449	0,000
M10.t	0,590	0,239	6,169	0,000	9,596	0,000
M11.t	1,665	0,003	7,734	0,000	7,177	0,000
M12.t	1,943	0,001	6,914	0,000	15,543	0,000
C1.t	4,943	0,000	2,207	0,222	4,483	0,000
C2.t	0,982	0,039	2,806	0,030	-0,196	0,781
C3.t	0,563	0,297	0,548	0,708	-2,506	0,002
C4.t	-5,528	0,000	-0,053	0,967	-2,597	0,000
C1.t.1	11,027	0,000	5,620	0,003	5,313	0,000
C2.t.1	3,494	0,000	11,228	0,000	9,890	0,000
C3.t.1	2,295	0,000	1,489	0,315	-1,988	0,015
C4.t.1	3,309	0,000	3,209	0,013	13,242	0,000
FITS	0,571	0,000	0,705	0,000	0,800	0,000

## Lampiran 54 Surat Keterangan Data dari Bank Indonesia



### SURAT KETERANGAN

Saya yang bertanda tangan di bawah ini, menerangkan bahwa:

1. Mahasiswa Jurusan Statistika FMIPA ITS:

Nama : Novi Ajeng Salehah  
NRP : 1313 100 051

melalui Surat No. 080848/IT2.1.1.3/TU.00.09/2017 tanggal 3 Januari 2017 telah mengajukan permohonan ijin untuk memperoleh data di instansi kami:

Nama Instansi : Bank Indonesia  
Departemen : Departemen Pengelolaan Uang

Berupa data "Inflow dan Outflow di Wilayah Jawa Timur periode bulan Januari 2005 sampai dengan Desember 2016" untuk keperluan Tugas Akhir Semester Genap 2016/2017.

2. ~~Tidak Keberatan/Keberatan~~\* nama instansi kami dicantumkan dalam Tugas Akhir mahasiswa Statistika yang akan disimpan di Perpustakaan ITS dan dibaca di lingkungan ITS.
3. ~~Tidak Keberatan/Keberatan~~\* bahwa hasil analisis Mahasiswa bersangkutan terhadap data yang diperoleh dari instansi kami dipublikasikan dalam E journal ITS yaitu Jurnal Sains dan Seni ITS.
4. Semua hasil analisis terhadap data yang diperoleh dari instansi kami merupakan hasil analisis pribadi mahasiswa yang bersangkutan.

Jakarta, 17 Juni 2017  
Departemen Pengelolaan Uang  
Kepala Grup,

  
Decymus  
Direktur

\*coret yang tidak perlu

## BIODATA PENULIS



Penulis memiliki nama lengkap Novi Ajeng Salehah yang biasa dipanggil Ajeng. Penulis lahir di Surabaya pada tanggal 02 November 1995. Penulis merupakan anak kedua dari Bapak Sadnawi dan Ibu Tlenik Triharsi. Penulis menempuh pendidikan SD di SDN Manukan Wetan I, pendidikan SMP di SMP Negeri 3 Surabaya dan SMA di SMA Negeri 5 Surabaya. Hingga akhirnya pada tahun 2013 penulis melanjutkan pendidikan di jenjang perguruan tinggi di departemen Statistika ITS melalui jalur SNMPTN Undangan yang terdaftar dengan NRP. 1313100051. Selama 4 tahun berkuliah di departemen Statistika ITS, penulis juga aktif di Divisi Professional Statistics (PSt) HIMASTA-ITS dengan jabatan terakhir sebagai Tim Ahli Departemen Analisis Data. Penulis juga berkesempatan menjadi Asisten Dosen untuk matakuliah Pengantar Metode Statistika dan Komputasi Statistika selama melewati masa perkuliahan di Statistika. Penulis juga ikut serta dalam ajang Program Kreativitas Mahasiswa (PKM) tahun 2016. Segala kritik dan saran serta diskusi lebih lanjut mengenai Tugas Akhir ini dapat dikirimkan melalui surat elektronik (*e-mail*) ke alamat [noviajeng.s@gmail.com](mailto:noviajeng.s@gmail.com).

